



João Pedro Gonçalves Evangelista

Licenciado em Ciências de Engenharia e Gestão Industrial

Aplicação de Métodos Estatísticos na Indústria Corticeira

Dissertação para obtenção do Grau de Mestre em
Engenharia e Gestão industrial

Orientador: Doutor José Fernando Gomes Requeijo,
Professor Auxiliar da Faculdade de Ciências e
Tecnologia, Universidade Nova de Lisboa

Júri:

Presidente: Professora Doutora Maria Celeste Rodrigues Jacinto
Arguente: Prof. Doutora Helena Maria Pereira Pinto Dourado Alvelos
Vogal: Prof. Doutor José Fernando Gomes Requeijo



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Setembro 2016

Aplicação de Métodos Estatísticos na Indústria Corticeira

Copyright © João Pedro Gonçalves Evangelista, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objectivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

À minha família ...

Agradecimentos

A realização desta dissertação foi possível graças à cooperação e intervenção de diversas pessoas as quais gostaria de deixar os meus agradecimentos.

Com esse intuito deixo expresso o meu reconhecimento:

Ao exemplar Professor Doutor José Gomes Requeijo, que proporcionou as condições necessárias à realização desta dissertação e prestou diretrizes técnicas de forma incansável, preciosa e sempre dedicada ao longo deste trabalho. Agradeço também todo o encorajamento e motivação prestados desde o início deste trabalho. Sem qualquer dúvida é um dos professores mais capazes com que tive o prazer de me cruzar ao longo do meu percurso académico e as suas palavras de motivação associadas aos seus ensinamentos foram determinantes para a execução deste estudo. Foi um privilégio tê-lo como orientador.

Presto também o meu reconhecimento ao Doutor Rui Dias por ter sido um dos elos fundamentais para dar início à execução deste estudo. Agradeço também à Diretora Industrial da EQUIPAR, Engenheira Maria Cortez, pela coordenação da formação e orientação no terreno ao longo da execução deste estudo. Agradeço também todo o apoio e autonomia que me foi fornecido, que permitiu com que esta dissertação fosse executada da melhor forma possível.

Ao Engenheiro Tiago Ferreira e ao Chefe da Manutenção Elétrica Luís Benito agradeço todo o apoio e conhecimentos acerca do micro-ondas que de forma paciente me foram transmitidos ao longo da minha passagem pela Unidade Industrial EQUIPAR.

À responsável de produção Isilda Gagueja cujo conhecimento e interpretação de todos os aspetos da fábrica foram determinantes para o meu enquadramento na EQUIPAR. Os meus mais sinceros agradecimentos pela sua contribuição, pelo seu apoio e principalmente pela sua paciência ao responder a todas as questões. Foi, sem qualquer dúvida, determinante.

Um agradecimento particular ao operador do ROSA Mário Ferreira, pelo apoio incansável e pela valiosa passagem de conhecimentos durante o período de amostragem. Espero que continue a formar ligações sólidas e a passar todo o seu saber de experiência feito a novos estagiários.

À alegre equipa do laboratório pelo seu apoio e a todos os engenheiros, responsáveis e operadores que revelaram interesse e se disponibilizaram para me apoiar na minha batalha.

Um sentido agradecimento aos meus amigos de sempre. Em especial ao Mário Almeida e ao Sérgio Ambrósio, pela vossa amizade, apoio e motivação inabaláveis e inenarráveis.

Um agradecimento muito especial à minha família. Pelo vosso auxílio e carinho que não têm preço, que me levaram até ao momento de conclusão desta dissertação. Vocês são os derradeiros responsáveis por eu atingir este objetivo. Espero que se sintam orgulhosos de mim.

Ao meu pai em peculiar, sei como este momento é particularmente especial para ti. Que fique registado que também é especial para mim.

Resumo

Tomar consciência que a noção de qualidade é um conceito praticamente omnipresente, aplicado nos mais distintos ramos da sociedade apesar do seu carácter ser por vezes abstrato e subjetivo, é um bom ponto de partida para entender que este é um conceito tem sido alvo de diversos estudos, sobre diferentes perspetivas, acerca do mesmo. As organizações recorrem cada vez mais a técnicas e ferramentas que permitam melhorar os seus processos, resultando este ato num aumento de competitividade das mesmas. A aplicação de métodos estatísticos é de enorme importância, fornecendo um suporte sólido da tomada de decisões nas organizações, uma vez que permite entender e modelar a variabilidade, validando assim os resultados que são obtidos ao longo das análises. No âmbito industrial, o planeamento e controlo estatístico de processo representa o conjunto que técnicas e ferramentas que procura satisfazer este propósito.

O desenho de experiências apresenta-se enquanto a ferramenta ideal para apurar quais são os parâmetros sobre os quais um determinado processo deverá operar de forma a que sejam obtidos os outputs desejados ou exista uma redução da variabilidade existente. Fazendo uso da base estatística é possível obter resultados fidedignos do processo. Por sua vez, as cartas de controlo apresentam-se enquanto uma ferramenta poderosa que permite controlar os processos, em tempo real, recorrendo a expressões gráficas das características controláveis do mesmo, permitindo analisar possíveis tendências que se possam verificar e apoiando também na redução da variabilidade dos processos. As cartas de controlo tradicionais (i.e. de Shewhart) baseiam-se num conjunto de pressupostos, relativos sobretudo à Normalidade e independência dos dados. Contudo, na prática, estes pressupostos nem sempre são validados. Mais concretamente, verifica-se a existência de autocorrelação em muitos dos dados referentes a processos industriais. Nesse caso, é necessário adequar as cartas de controlo para que sejam capazes de servir o seu objetivo, lidando com o efeito presente nos dados das auto-correlações existentes.

A presente dissertação aborda estas questões, recorrendo a diferentes técnicas estatísticas tais como testes de hipóteses, ANOVA, controlo estatístico univariado e controlo estatístico multivariado com dados auto correlacionados e modelação de processos recorrendo aos modelos ARIMA.

As metodologias desenvolvidas foram implementadas na fábrica EQUIPAR Amorim & Irmãos S.A. com o objetivo de munir a organização com ferramentas adequadas de controlo estatístico dos seus processos produtivos que potenciam a melhoria dos seus processos, permitindo a identificação das causas de variação responsáveis pela variabilidade verificada nos seus processos e a execução de ações corretivas sobre as mesmas.

Palavras-chave: Teste de hipóteses, Análise de Variância, Desenho de Experiências, Controlo Estatístico do Processo, Cartas de Controlo Univariadas e Multivariadas, Autocorrelação, Modelos ARIMA, Cortiça

Abstract

To be aware that the notion of quality is a concept practically ubiquitous, applied in the most different branches of society despite their character being abstract and subjective sometimes, proves to be a good starting point to understand that this is a concept that has been the subject of several studies under different perspectives. Organizations increasingly use new techniques and tools to optimize their processes, resulting in increased competitiveness. The application of statistical methods is of great importance, providing a solid support during decision-making actions inside the organizations as it allows us to understand and model the variability, thus validating the results that are obtained during the analysis. In the industrial scope, planning and statistical control process is the set of techniques and tools that seeks to meet this purpose.

The design of experiments is presented as an ideal tool to determine on which parameters should a certain process operate so that the desired outputs be obtained or there a reduction of variability is obtained. Making use of the statistical basis it is possible to obtain reliable results of the process. In turn, the control charts are presented as a powerful tool to control the processes in real time, using graphical expressions of controllable features of it, allowing to analyse possible trends that may occur and support also in reducing variability inside processes. Traditional control cards (*i.e.* Shewhart) based on a set of assumptions regarding independence and particularly to normal data. However, in practice, these assumptions are not always validated. More specifically, there is the autocorrelation data in many industrial processes. In this case, it is necessary to adjust the control card to be able to serve its purpose, dealing with this effect on the existing auto-correlation data.

This dissertation addresses these issues, using different statistical techniques such as hypothesis testing, ANOVA, univariate statistical control and statistical control multivariable self-correlated data and modelling processes based on ARIMA models.

The methodologies exercised were implemented at the plant EQUIPAR Amorim & Irmãos S.A. in order to equip the organization with appropriate tools of statistical control of their production processes that enhance the improvement of its processes, enabling the identification of the causes of variation responsible for the observed variability in its processes and the implementation of corrective actions on them.

Keywords: Hypothesis Testing, Analysis of Variance, ANOVA, Design of Experiments, Process Statistical Control, Control Charts, univariate study, study Multivariate, Autocorrelation, FACE, FACEP, Cork

Índice

1.	Introdução	1
1.1.	Motivação	1
1.2.	Objetivo	2
1.3.	Estrutura da dissertação	2
2.	Contextualização Teórica.....	5
2.1.	Introdução.....	5
2.2.	Contextualização Histórica.....	5
2.3.	Qualidade	6
2.4.	Gestão pela Qualidade Total (TQM)	7
2.5.	Desenho de Experiências (DOE)	10
2.5.1	Desenho Fatorial (Dois Fatores a Vários Níveis)	15
2.5.2	Análise de Variância do Modelo de Efeitos Fixos	17
2.5.3	Análise de Resíduos.....	18
2.5.4	Tomada de Decisão	22
2.5.5	Considerações Finais Acerca do DOE	22
2.6.	Controlo Estatístico Para Dados Independentes	23
2.6.1	Controlo Estatístico de Processo Tradicional.....	23
2.6.2	Princípios da Abordagem Tradicional às Cartas de Controlo	25
2.6.3	Medidas de Desempenho das Cartas de Controlo	27
2.6.4	Tipos de Cartas de Controlo	28
2.6.5	Regras Para Detecção de Causas Especiais de Variação.....	30
2.6.6	Cartas das Observações Individuais e Amplitudes Móveis	32
2.6.7	Estudo da Capacidade do Processo	33
2.7.	Controlo de processos com Dados Auto Correlacionados	35
2.7.1	Séries Temporais	37
2.7.2	Verificação da Independência dos dados	38

2.7.3	FAC e FACP	38
2.7.4	Modelos Integrados Mistos Auto-Regressivos de Médias Móveis	40
2.7.5	Processo AR(p)	42
2.7.6	Processo MA(q)	42
2.7.7	Processo ARMA (p,q)	42
2.7.8	Caracterização dos Correlogramas.....	43
2.8.	Controlo Estatístico Multivariado do Processo.....	45
2.8.1	Cartas de controlo Multivariadas – Observações Individuais	46
2.8.2	Interpretação da carta de controlo (T^2)	47
2.8.3	Estatística d	48
2.8.4	Capacidade Multivariada do Processo	48
2.9.	Outros Conceitos Estatísticos	50
2.9.1	Teste de Hipóteses.....	50
2.9.2	Diferença de Duas Médias	52
3.	Descrição da Organização.....	55
3.1.	Unidade Industrial EQUIPAR - Amorim & Irmãos, S.A	55
3.2.	Produtos	56
3.3.	Fluxo de Produção	57
3.3.1	Sector e Processo ROSA.....	59
3.4.	Método de Amostragem	62
4.	Componente Experimental.....	63
4.1.	Desenhos de Experiências.....	63
4.1.1	Caracterização das Diferenças na Matéria-Prima	63
4.1.2	Fase de Amostragem	66
4.1.3	Resultados e Verificação dos Pressupostos	66
4.2.	Cartas de Controlo, Estudo Univariado.....	79
4.2.1	Independência dos Dados.....	80
4.2.2	Cartas de Controlo Univariadas	83

4.3.	Cartas de Controlo, Estudo Multivariado.....	91
4.3.1	Fase 1 do Estudo Multivariado	91
4.3.2	Fase 2 do Estudo Multivariado	93
4.4.	Confronto de resultados	94
4.4.1	Fase 2 do Estudo Multivariado	94
4.5.	Diagrama de Ishikawa	94
5.	Conclusão	96
5.1.	Resultados e Ilações	96
5.2.	Sugestões de Melhoria.....	98
5.3.	Sugestões para Trabalhos Futuros	100
6.	Referências Bibliográficas.....	103
7.	Anexos	109
7.1.	Anexos I – Organigrama da Amorim (Rolhas)	109
7.2.	Anexo II – Tabelas e Fórmulas Estatísticas	110
7.3.	Anexo III – Testes de hipóteses	112
7.3.1	Entrada do MO1	112
7.3.2	Saída MO1	114
7.3.3	Comparação de desenhos	116
7.4.	Anexo IV – Cálculos DOE	118
7.5.	Anexo V – Processo Univariadas	119
7.6.	Anexo VI – Processo Multivariadas.....	138

Índice de figuras

Figura 2.1 - Trilogia de Juran.	8
Figura 2.2 - Modelo geral de um processo ou sistema.	11
Figura 2.3 - Probabilidades da Distribuição Normal.	20
Figura 2.4 - Resíduos e ordem das experiências.	21
Figura 2.5 - Resíduos e valores previstos.	22
Figura 2.6 - Processo de melhoria utilizando cartas de controlo	25
Figura 2.7 - Exemplo Carta de Controlo	26
Figura 2.8 - Regras para a detecção de causas especiais	31
Figura 2.9 - Exemplo de níveis de precisão	34
Figura 2.10 - FACE, Função de Auto Correlação Estimada.	39
Figura 2.11 - Fases na elaboração de um modelo ARIMA	44
Figura 2.12 - Região modificada do processo $p=2$	49
Figura 3.1 - Organigrama da Corticeira Amorim	55
Figura 3.2 - Fluxograma, curso produtivo. EQUIPAR – Amorim & Irmãos S.A.	58
Figura 3.3 - Fluxograma Rosa RCT, EQUIPAR – Amorim & Irmãos S.A.	60
Figura 4.1 - Representação de Silos ROSA	63
Figura 4.2- Entrada MO. Diferenças estatísticas (média) entre fases do silo para humidade relativa	64
Figura 4.3 - Entrada MO. Diferenças estatísticas (média) entre fases do silo para massa volúmica corrigida a 8%.....	64
Figura 4.4- Saída MO. Diferenças estatísticas (média) entre fases do silo para humidade relativa	65
Figura 4.5 - Saída MO. Diferenças estatísticas (média) entre fases do silo para massa volúmica corrigida a 8%.....	65
Figura 4.6 - Verificação da Normalidade residual para DOE1 (Massa Volúmica)	67
Figura 4.7 - Verificação da homogeneidade residual para DOE1 (Massa Volúmica)	68
Figura 4.8 - Verificação da independência para DOE1 (Massa Volúmica)	68

Figura 4.9 - Superfície de resposta DOE1 (Massa Volúmica)	69
Figura 4.10 - Verificação da normalidade residual para DOE2 (Humidade Relativa)	71
Figura 4.11 - Verificação da homogeneidade residual para DOE 2 (Humidade Relativa)	71
Figura 4.12 - Verificação da independência DOE2 (Humidade Relativa)	72
Figura 4.13 - Superfície de resposta DOE2 (Humidade Relativa)	73
Figura 4.14 - Verificação da Normalidade DOE 3 (Massa Volúmica)	74
Figura 4.15 - Verificação da homogeneidade da variância DOE 3 (Massa Volúmica)	75
Figura 4.16 - Verificação da independência DOE 3 (Massa Volúmica)	75
Figura 4.17 - Superfície de resposta DOE3 (Massa Volúmica)	76
Figura 4.18 - Verificação da normalidade DOE4 (Humidade Relativa)	77
Figura 4.19 - Verificação homogeneidade da variância DOE4 (Humidade Relativa)	78
Figura 4.20 - Verificação da independência DOE4 (Humidade Relativa)	78
Figura 4.21 - FAC (Massa Volúmica)	80
Figura 4.22 - FACP (Massa Volúmica)	81
Figura 4.23 - FAC (Humidade)	81
Figura 4.24 - FACP (Humidade)	82
Figura 4.25 - Carta de Controlo Resíduos, Fase 1 (Massa Volúmica)	84
Figura 4.26 - Carta de Controlo Médias Móveis, Fase 1 (Massa Volúmica)	84
Figura 4.27 - Carta de Controlo Resíduos, Fase 1 (Humidade)	85
Figura 4.28 - Carta de Controlo Médias Móveis, Fase 1 (Humidade)	85
Figura 4.29 - FACE Final (Massa Volúmica)	86
Figura 4.30 - FACPE Final (Massa Volúmica)	87
Figura 4.31 - FACE Final (Humidade)	87
Figura 4.32 - FACPE Final (Humidade)	88
Figura 4.33 - Carta de Controlo Erros de Previsão, Massa Volúmica, Fase 2	89
Figura 4.34 - Carta de Controlo Amplitudes Móveis, Massa Volúmica, Fase 2	89
Figura 4.35 - Carta de Controlo Erros de Previsão, Humidade, Fase 2	90
Figura 4.36 - Carta de Controlo Amplitudes Móveis, Humidade, Fase 2	90

Figura 4.37 - Carta de Controlo T^2 , Massa Volúmica Corrigida e Humidade, Fase 1	92
Figura 4.38 - Carta de Controlo T^2 , Massa Volúmica Corrigida e Humidade, Fase 2	93
Figura 4.39 - Diagrama de Ishikawa, Causas da variabilidade elevada existente no MO1	95
Figura 7.1 - Organigrama do Grupo Amorim (Rolhas)	109
Figura 7.2 - FAC Iteração 1 (Massa Volúmica)	121
Figura 7.3 - FACP Iteração 1 (Massa Volúmica)	122
Figura 7.4 - FAC Iteração 1 (Humidade Relativa)	122
Figura 7.5 - FACP Iteração 1 (Humidade Relativa)	123
Figura 7.6 – Modelo ARIMA Iteração 1 (Massa Volúmica)	123
Figura 7.7 - Modelo ARIMA Iteração 1 (Humidade Relativa)	123
Figura 7.8 - Carta de Controlo X Iteração 1 (Massa Volúmica)	124
Figura 7.9 - Carta de Controlo MR Iteração 1 (Massa Volúmica)	124
Figura 7.10 - Carta de Controlo X Iteração 1 (Humidade Relativa)	125
Figura 7.11 - Carta de Controlo MR Iteração 1 (Humidade Relativa)	125
Figura 7.12 - Modelo ARIMA Iteração 2 (Massa Volúmica)	126
Figura 7.13 - Modelo ARIMA Iteração 2 (Humidade Relativa)	126
Figura 7.14 - Carta de Controlo X Iteração 2 (Massa Volúmica)	127
Figura 7.15 - Carta de Controlo MR Iteração 2 (Massa Volúmica)	127
Figura 7.16 - Carta de Controlo X Iteração 2 (Humidade Relativa)	128
Figura 7.17 - Carta de Controlo MR Iteração 2 (Humidade Relativa)	128
Figura 7.18 - Modelo ARIMA Iteração 3 (Massa Volúmica)	129
Figura 7.19 - Modelo ARIMA Iteração 3 (Humidade Relativa)	129
Figura 7.20 - Carta de Controlo X Iteração 3 (Massa Volúmica)	129
Figura 7.21 - Carta de Controlo MR Iteração 3 (Massa Volúmica)	130
Figura 7.22 - Carta de Controlo X Iteração 3 (Humidade Relativa)	130
Figura 7.23 - Carta de Controlo MR Iteração 3 (Humidade Relativa)	131
Figura 7.24 - Modelo ARIMA Iteração 4 (Humidade Relativa)	131
Figura 7.25 - Carta de Controlo X Iteração 4 (Humidade Relativa)	132

Figura 7.26 - Carta de Controlo MR Iteração 4 (Humidade Relativa)	132
Figura 7.27 - FACE Iteração Final (Massa Volúmica).....	133
Figura 7.28 - FACPE Iteração Final (Massa Volúmica)	133
Figura 7.29 - FACE Iteração Final (Humidade Relativa)	134
Figura 7.30 - FACPE Iteração Final (Humidade Relativa)	134
Figura 7.31 - Histograma Resíduos, Teste Kolmogorov-Smirnov (Massa Volúmica)	135
Figura 7.32 - Histograma Resíduos, Teste Kolmogorov-Smirnov (Humidade Relativa)	135
Figura 7.33 - Carta de controlo dos Erros de Previsão, Fase 2 (Massa Volúmica).....	136
Figura 7.34 - Carta de controlo das Amplitudes Móveis, Fase 2 (Massa Volúmica)	136
Figura 7.35 - Carta de controlo dos Erros de Previsão, Fase 2 (Humidade Relativa).....	137
Figura 7.36 - Carta de controlo das Amplitudes Móveis, Fase 2 (Humidade Relativa)	137
Figura 7.37- FAC Iteração 1 (Massa Volúmica).....	138
Figura 7.38 - FACP Iteração 1 (Massa Volúmica)	139
Figura 7.39 - FAC Iteração 1 (Humidade).....	139
Figura 7.40 - FACP Iteração 1 (Humidade)	140
Figura 7.41 - Modelo ARIMA Iteração 1 (Massa Volúmica) T^2	143
Figura 7.42 -Modelo ARIMA Iteração 1 (Humidade Relativa) T^2	143
Figura 7.43 - Modelo ARIMA Iteração 2 (Massa Volúmica) T^2	143
Figura 7.44 - Modelo ARIMA Iteração 2 (Humidade Relativa) T^2	144
Figura 7.45 - Modelo ARIMA Iteração 3 (Massa Volúmica) T^2	144
Figura 7.46 - Modelo ARIMA Iteração 3 (Humidade Relativa) T^2	144
Figura 7.47 - Modelo ARIMA Iteração 4 (Massa Volúmica) T^2	145
Figura 7.48 - Modelo ARIMA Iteração 4 (Humidade) T^2	145
Figura 7.49 - Modelo ARIMA Iteração 5 (Massa Volúmica) T^2	145
Figura 7.50 - Modelo ARIMA Iteração 5 (Humidade Relativa) T^2	146
Figura 7.51 - Modelo ARIMA Iteração 6 (Massa Volúmica) T^2	146
Figura 7.52 - Modelo ARIMA Iteração 6 (Humidade Relativa) T^2	146
Figura 7.53 - FACE Final T^2 (Massa Volúmica)	147

Figura 7.54 - FACPE Final T^2 (Massa Volúmica)	147
Figura 7.55 - FACE Final T^2 (Humidade Relativa)	148
Figura 7.56 - FACPE Final T^2 (Humidade Relativa)	148
Figura 7.57 - Vector Média Final, Fase 1, T^2	149
Figura 7.58 - Índices de capacidade do processo, Fase 1, T_2	149
Figura 7.59 - Histograma Resíduos, Teste Kolmogorov-Smirnov (Massa Volúmica) T^2	149
Figura 7.60 - Histograma Resíduos, Teste Kolmogorov-Smirnov (Humidade Relativa) T^2	150
Figura 7.61 - Carta de Controlo T^2 , Fase 2	150

Índice de tabelas

Tabela 2.1 - Arranjo geral de dois fatores a vários níveis.....	16
Tabela 2.2- ANOVA.....	18
Tabela 2.3 - Procedimentos de construção das cartas de controlo	26
Tabela 2.4 - Procedimentos de construção das cartas de controlo	29
Tabela 2.5– Limites de controlo para cartas de resíduos e amplitudes móveis	36
Tabela 2.6 - Carta de controlo dos erros de previsão e amplitudes móveis.....	37
Tabela 2.7 - Critério de caracterização dos modelos ARIMA	43
Tabela 3.1 -Caracterização de granulados, EQUIPAR S.A.	56
Tabela 4.1 - Resultados DOE 1 Massa Volúmica.....	67
Tabela 4.2 - ANOVA para DOE1 (Massa Volúmica).....	69
Tabela 4.3 - Melhores Níveis DOE1 Massa Volúmica	70
Tabela 4.4 - Resultados DOE2 (Humidade Relativa)	70
Tabela 4.5 - ANOVA para DOE2 (Humidade Relativa)	72
Tabela 4.6 - Melhores Níveis DOE2 (Humidade Relativa)	73
Tabela 4.7 - Resultados DOE3 (Massa Volúmica)	74
Tabela 4.8 - ANOVA DOE3 (Massa Volúmica).....	76
Tabela 4.9 - Melhores níveis DOE3 (Massa Volúmica)	77
Tabela 4.10 - Resultados DOE4 (Humidade Relativa)	77
Tabela 4.11 - ANOVA DOE 4 Humidade Relativa	79
Tabela 4.12 - Parâmetros do processo para Massa Volúmica e Humidade Relativa	82
Tabela 4.13 - Resultados teste de normalidade univariadas	86
Tabela 4.14 - Especificações e Capacidades, Massa Volúmica Corrigida e Humidade Relativa	88
Tabela 4.15 - Resultados teste de normalidade multivariadas	92
Tabela 4.16 - Resultados capacidade para cartas multivariadas	93
Tabela 4.17 - Causas especiais substituídas, Estudo Univariado vs Estudo Multivariado, Fase 1	94

Tabela 7.1 - Critérios de interpretação do p-value	110
Tabela 7.2 – Valores críticos associados à Distribuição da Estatística D (Lilliefors).....	110
Tabela 7.3 - Constantes para Cartas Tradicionais de Variáveis.....	111
Tabela 7.4 - Teste de Hipóteses da Média para MV (Início/Meio Silo) Entrada MO1	112
Tabela 7.5 - Teste de Hipóteses da Média para MV (Início/ Fim Silo) Entrada MO1	112
Tabela 7.6 - Teste de Hipóteses da Média para MV (Fim/Meio Silo) Entrada MO1	113
Tabela 7.7 - Teste de Hipóteses da Média para Humidade Relativa (Início/Meio Silo) Entrada MO1	113
Tabela 7.8 - Teste de Hipóteses da Média para Humidade Relativa (Início/ Fim Silo) Entrada MO1	113
Tabela 7.9 - Teste de Hipóteses da Média para Humidade Relativa (Fim/Meio Silo) Entrada MO1	114
Tabela 7.10 - Teste de Hipóteses da Média para MV (Início/Meio Silo) Saída MO1	114
Tabela 7.11 - Teste de Hipóteses da Média para MV (Início/ Fim Silo) Saída MO1	114
Tabela 7.12 - Teste de Hipóteses da Média para MV (Fim/Meio Silo) Saída MO1	115
Tabela 7.13 - Teste de Hipóteses da Média para Humidade Relativa (Início/Meio Silo) Saída MO1	115
Tabela 7.14 - Teste de Hipóteses da Média para Humidade (Início/ Fim Silo) Saída MO1 ...	115
Tabela 7.15 - Teste de Hipóteses da Média para Humidade Relativa (Fim/Meio Silo) Saída MO1	116
Tabela 7.16 - Teste de Hipóteses para a Variância DOE's Massa Volúmica.....	116
Tabela 7.17 - Teste de hipóteses para DOE's Humidade Relativa	116
Tabela 7.18 - Distâncias ao target DOE 1	118
Tabela 7.19 - Distâncias ao target DOE 2	118
Tabela 7.20 - Distâncias ao target DOE 3	118
Tabela 7.21 - Distâncias ao target DOE 4	118
Tabela 7.22 - Série de dados original e respetivos resíduos	119
Tabela 7.23 - Causas Especiais de Variação Carta T ² , Fase 1, Iteração 1.....	140
Tabela 7.24 - Matriz de covariâncias S, Fase 1, T ²	149

Lista de abreviaturas

ANOVA	Analysis Of Variance
AR(p)	Modelo auto-regressivo de ordem p
ARMA(p,q)	Modelo misto, auto-regressivo e de médias móveis
ARIMA(p,d,q)	Modelo autoregressivo, integrativo e de médias móveis
ARL	“Average Run Length”
ARL _{EC}	ARL quando o processo está sob controlo estatístico
ARL _{FC}	ARL quando o processo não está sob controlo estatístico
B	Operador de desfasamentos
C _p	Índice de Capacidade Potencial do Processo
C _{pk}	Índice de Capacidade do Processo
(C _{pk}) _I , (C _{pk}) _S	Índice de Capacidade Inferior ou Superior
C _{pM}	Índice de Capacidade Multivariado
d	Estatística de teste Kolmogorov-Smirnov
d _i	Estatística para determinar a variável i responsável pela situação fora de controlo da carta T ²
D _{crítico}	Valor crítico para o teste Kolmogorov-Smirnov
DOE	Desenho de Experiências
e _t	Resíduo no instante t; Erro de previsão no instante t
F _{α; p; (m – p – 1)}	Percentil à direita da distribuição de Fischer
F _o	Valor crítico para o teste de Fischer (análise de variância)
g.l.	Graus de liberdade
FAC,FACP	Função autocorrelação, Função autocorrelação parcial
FACE, FACEP	Função autocorrelação estimada, função autocorrelação parcial estimada
ISO	“International Organization for Standardization”
LC	Linha Central
LI	Índice de capacidade multivariado
LIC, LSC	Limite Inferior de Controlo, Limite Superior de Controlo

LIP, LSP	Limite Inferior de Especificação, Limite Superior de Especificação
MA(q)	Médias Móveis ordem q
MR	Amplitude móvel
MR _i	Amplitude móvel amostra i
\overline{MR}	Média das amplitudes móveis
MO	Micro-Ondas
m	Número de amostras
MS	“Mean Square”
N	Número de dados
N (μ, σ^2)	Distribuição Normal com média μ e variância σ^2
n	Dimensão da amostra; número de réplicas DOE
n _i	Dimensão da amostra i
PV	Índice de capacidade multivariado
p	Nº de características da qualidade em estudo no controlo multivariado do processo
ROSA	Rate of Optimal Steam Application
r _k	Valor estimado de p _k
S ⁻¹	Matriz inversa das covariâncias amostrais
S ²	Variância Amostral
S _{jh}	Covariância amostral entre as características j e h
SPC	Statistical Process Control
SS	“Sum of Squares”
T ²	Estatística de Hotteling
T _i ²	Valor estatística Hotteling determinada excluindo a variável i
TCA	2,4,6 Tricloroanisol
UN	Unidade Industrial
MP	Matéria-Prima
X	Característica da qualidade
\bar{X}	Média amostral

\bar{X}_j	Médias das m observações para a característica j
\bar{X}_k	Vetor média para as p médias de amostras em cada instante
α	Nível de significância; Risco tipo I (Risco Produtor)
β	Risco tipo II (Risco Consumidor)
$B_{\alpha;p/2,(m-p-1)/2}$	Percentil à direita da distribuição Beta
χ^2	Estatística Qui-Quadrado
$\chi^2_{\alpha;p}$	Percentil à direita da distribuição Qui-Quadrado
$\Phi_p(B)$	Polinómio auto-regressivo ordem p
ϕ_{kk}	Coefficiente de autocorrelação parcial
μ	Média Processo
μ_i	Média do Processo referente à característica da qualidade i
θ_j	Parâmetros ordem j no modelo MA ou ARMA
$\theta_q(B)$	Polinómio médias móveis de ordem q
Σ	Matriz das covariâncias para as p características
ρ_k	Coefficiente autocorrelação de desfasamento k
σ	Desvio padrão amostral
σ^2	Variância do processo
$\hat{\sigma}$	Desvio padrão estimado
ξ	Parâmetro para determinação média do processo de um modelo AR(p)
∇	Operador de desfasamento

1. Introdução

O aumento de competitividade por parte das organizações tem levado a grandes progressos no seio industrial e a uma incessante procura por parte das mesmas pela excelência operacional, garantindo que estão num processo de melhoria constante, tirando o melhor proveito possível dos recursos disponíveis enquanto, simultaneamente, se minimizam os custos inerentes aos seus processos. O mercado, por sua vez, impõe que as organizações forneçam produtos fiáveis a baixo custo. Todos estes motivos levam a que a Qualidade assuma um papel preponderante nas organizações, tornando-se imprescindível para o sucesso das mesmas.

A aplicação de métodos estatísticos à Qualidade, nomeadamente apoiando o estudo da variabilidade, torna as organizações aptas a aprofundar o conhecimento dos seus processos e desenvolver os mesmos, tornando a base de tomada de decisões por parte da gestão de topo mais sólida. Por este motivo, as análises estatísticas assumem cada vez mais um papel basilar nas alturas de tomada de decisão nas organizações.

Por sua vez, o controlo estatístico de processo (SPC), assentando nesta base estatística, assume o papel de ferramenta de controlo estatístico de processos no seio industrial, uma vez que através do mesmo é possível realizar avaliações preliminares, estimar os parâmetros de um determinado processo, avaliar a sua capacidade face às especificações técnicas utilizadas e, numa segunda fase, monitorizar o processo e identificar falhas / alterações no mesmo. Assim sendo, demonstra ser uma ferramenta útil na deteção destas variações, levando em última análise à redução de custos nas organizações.

1.1. Motivação

Tal como foi referido anteriormente, o facto de as organizações terem sofrido grandes modificações face ao aumento de competitividade e exigência dos mercados levou a que as estas apostassem na melhoria da qualidade dos processos e do produto final, garantido que o produto era sempre bem realizado à primeira tentativa, recorrendo à implementação de técnicas estatísticas nas grandes produções.

A presente dissertação foi desenvolvida no âmbito do planeamento e controlo estatístico de processo na fábrica EQUIPAR – Amorim & Irmãos, S.A, situada na Zona Industrial do Monte da Barca (Coruche). Esta é uma empresa ligada à indústria corticeira, parte integrante do Grupo Amorim, tratando-se de uma organização industrial destinada à produção de rolhas derivadas do granulado de cortiça.

Essa dissertação foi elaborada no sentido de responder ao desafio proposto de aprofundar o conhecimento e controlo da organização sobre um dos seus processos. Após o reconhecimento

do processo chegou-se à conclusão que o ideal seria a aplicação de metodologias ligadas ao planeamento e controlo estatístico de processos que se adequassem à realidade da organização.

Sendo esta uma organização de referência mundial e tendo em conta os padrões elevados a que o seu produto deve corresponder, a implementação de métodos do controlo de processo é imperativa para identificar as causas especiais de variação presentes no processo e reduzir a variabilidade inerente ao mesmo.

No âmbito desta dissertação, o processo em estudo é referente ao processamento de granulado no micro-ondas 1 da Equipar.

1.2. Objetivo

O objetivo global que foi mantido em mente ao longo da execução desta dissertação foi o de perceber exatamente quais os melhores parâmetros sobre os quais o processo opera e também o desenvolvimento e implementação de métodos de controlo estatístico adequados que permitissem monitorizar um processo específico na EQUIPAR S.A. Imperativamente era necessário entender quais são as diferentes técnicas que, neste âmbito, eram adequadas aos desafios que foram propostos e ao sistema em causa, nomeadamente no que toca ao tratamento e controlo de processos que apresentem dados auto correlacionados.

O primeiro objetivo era perceber exatamente sobre que parâmetros é que o processo tinha a melhor *performance* face às necessidades da organização, *i.e.* descobrir a parametrização que levasse a uma maior aproximação dos valores médios do processo ao seu valor alvo (*target*). Foi com o intuito de concretizar este primeiro objetivo que foi aplicado um desenho de experiências de dois fatores a vários níveis no micro-ondas 1.

O segundo objetivo era implementar um modelo de controlo estatístico de processo, no mesmo ponto, procedimento que passou pela identificação de auto correlação nas observações da população em estudo e pelo tratamento dos respetivos resíduos de forma a que o efeito da auto correlação fosse retirado e fosse possível implementar o controlo estatístico de processo adequadamente.

Finda a aplicação prática, pretendia-se ainda identificar pontos de melhoria e sugerir outras perspetivas a serem exploradas com novos estudos, maioritariamente no âmbito do controlo estatístico de processo.

1.3. Estrutura da dissertação

A dissertação divide-se em 5 capítulos que visam fornecer um contexto e demonstrar ao leitor o trabalho prático que foi elaborado.

O primeiro capítulo, referente a este texto, visa fazer um enquadramento geral das temáticas que foram aplicadas, sobre a forma de breve introdução à dissertação. Visa também esclarecer qual foi a relevância do trabalho desenvolvido, os objetivos da execução e a estrutura da mesma.

O segundo capítulo visa fornecer ao leitor uma contextualização teórica do planeamento e controlo estatístico de processos, nomeadamente descrevendo as raízes desta temática deste o conceito de Qualidade à Gestão pela Qualidade Total. Após estas explicações, passa-se à exploração mais concreta das metodologias aplicadas ao longo da dissertação, particularmente, a exploração do Desenho de Experiências de dois fatores a vários níveis e verificação dos respetivos pressupostos, naturais à execução desta metodologia. Procede-se ainda à descrição das cartas de controlo, colocando o foco nos casos em que os pressupostos de independência e da Normalidade não são verificados, tanto do ponto de vista do controlo estatístico de processo univariado como o multivariado. Esta descrição inclui o método de avaliação das medidas de desempenho das cartas de controlo, a identificação e interpretação de causas especiais de variação, o estudo da capacidade dos processos e método de abordagem para dados auto correlacionados.

O terceiro capítulo contempla a apresentação da organização onde o estudo foi realizado, indicando-se uma breve descrição da EQUIPAR e da Corticeira Amorim, aludindo aos seus processos de fabrico, produtos fabricados e à organização da própria empresa.

O capítulo 4 por sua vez, aborda o caso de estudo desenvolvido, dando-se ênfase a toda a parte relacionada com o tratamento de dados e apresentação dos resultados experimentais, tendo por base as metodologias apresentadas no capítulo 2

O capítulo 5, por fim, faz um breve resumo das ilações retiradas ao longo da execução dos trabalhos associados à dissertação e apresenta algumas sugestões de melhoria e de estudos futuros para a organização.

2. Contextualização Teórica

2.1. Introdução

Através deste capítulo pretende-se apresentar alguns conceitos teóricos, fundamentais, que envolvem e sustentam o trabalho prático desenvolvido.

2.2. Contextualização Histórica

O termo “Qualidade” por si só é um tema subjetivo, que não tem uma definição única e que depende sempre, parcialmente, do contexto em que está a ser utilizado ou aplicado.

A qualidade desde sempre, ao longo do tempo, foi um fator inerente à natureza humana, tendo sempre sido utilizado ao longo da história sobre diversas perspetivas. Mesmo nos primórdios das civilizações humanas existia uma preocupação para executar bem os trabalhos, quer fosse através da escolha dos materiais mais adequados para construir determinadas ferramentas ou definindo os tamanhos mais adequados para as mesmas. Estes eram os indícios em menor escala de alguns conceitos transversais ao conceito de qualidade tais como a normalização, a metrologia e o controlo de qualidade. Mais tarde, estabeleciam-se relações entre quem produzia e quem consumia, dando ênfase à figura do artesão. Este apurava quais eram as necessidades dos clientes e, no fundo, ainda que de forma primária, executava todas as operações produtivas, de cadeia de abastecimento e de pós-venda, para procurar satisfazer as necessidades que os clientes lhe expunham. Com o natural crescimento dos aglomerados populacionais surgiu um aumento da procura e começaram a surgir as primeiras oficinas de artesãos, lideradas por um mestre (Pereira e Requeijo, 2012).

Mais tarde, com a continuação do desenvolvimento dos mercados, acabou por existir um excesso de procura face à capacidade de oferta, pelo que a preocupação das organizações passava quase que exclusivamente pelas quantidades produzidas. Nesta conjuntura, face aos objetivos das empresas, a qualidade era vista enquanto uma oposição, pondo sempre ênfase na produção em virtude da qualidade.

Contudo no século XIX paralelamente à revolução Industrial começou a ser importante criar o produto com especificações corretas o suficiente para que mais tarde não fossem necessários ajustes. Inspeção dos produtos à saída começou a ser a norma de qualidade por ser considerada mais barata do que intervenção no processo para prevenir possíveis defeitos. Contudo mais tarde, com a evolução que se verificou nos sistemas produtivos e devido à crescente competitividade, esta opção começou a requerer demasiados recursos e por esse motivo, mais tarde, surgiu o conceito de inspeção por amostragem. Surgem os primeiros estudos a relacionar o risco do consumidor e do produtor com as dimensões de amostra e também, eventualmente, o conceito de cartas de controlo. (Mast, 2008). Já no século XX houve um aumento incrível na qualidade dos produtos, ao mesmo tempo que os preços diminuíram dramaticamente (Mast, 2006).

Mais tarde, após alguns desenvolvimentos do conceito por parte de autores como Taguchi, Montgomery, Deming, Juran, entre outros, vão surgindo diversos conceitos e visões acerca do que é Qualidade e todas as suas vertentes.

Nomeadamente, tendo como base as filosofias de Deming e Juran, em 1980 aparecem as primeiras reflexões acerca da Gestão pela Qualidade Total enquanto estratégia de implementação e gestão de operações, tendo em vista a melhoria da qualidade através do envolvimento de todos os intervenientes numa organização, tendo em consciência o conceito de melhoria contínua a um nível global (Montgomery, 2013b).

É importante frisar que no final do século XX foram desenvolvidos os primeiros *standards* Internacionais acerca de Sistema da Qualidade, através da criação das normas ISO 9000 por parte da *International Standards Organization* (ISO).

2.3. Qualidade

Como aludido no tópico da contextualização histórica, o termo “qualidade” apesar de ser recorrentemente utilizado quer em contexto social, quer profissional, demonstra ser bastante mais complexo do que aquilo que é esperado numa primeira instância, especialmente quando se tem em conta a sua frequência de utilização em contexto quotidiano. Isto prende-se ao facto de o conceito ser lato por si só e do seu significado específico depender parcialmente da perspectiva de quem o aplica e do contexto em que é aplicado (e.g. indústria/produção ou serviços). É nesta linha de raciocínio que Chandra (2001) refere que a qualidade pode ser definida de diversas formas, podendo dar-se ênfase a diversos fatores desde a “satisfação dos requisitos dos clientes” à “aptidão para utilização” e ainda à “conformidade com requisitos”.

Chandra (2001) refere também que qualquer definição de qualidade deve incluir os clientes, cuja satisfação deve ser o alvo principal de qualquer negócio. Chandra (2001) acentua ainda que os mercados mundiais demonstram que a qualidade é um dos fatores mais importantes para o sucesso e crescimento de um negócio, facto que é recorrentemente acentuado por autores distintos até ao momento.

Mitra (2008) refere, na mesma linha de raciocínio, que a força motriz que é responsável por determinar o nível de qualidade associado/exigido de um produto ou serviço é o cliente. Assim sendo, os níveis de qualidade devem variar consoante as necessidades dos clientes.

Juntando as duas ideias gerais apresentadas acima, a de que a definição de qualidade varia parcialmente consoante o contexto em que se insere e a obrigação de esta satisfazer sempre a necessidade do cliente, torna-se necessário encontrar uma definição de qualidade adequada ao contexto deste trabalho.

Assim sendo, atendendo o contexto prático em que o trabalho foi desenvolvido considerou-se de certo modo como máxima a abordagem de Montgomery (2013a) que define a qualidade

enquanto conceito inversamente proporcional à variabilidade. Um conceito simples, mas como dita a expressão “a suprema excelência está na simplicidade”.

É importante refletir sobre o facto de estas iniciativas, ligadas a aumentos de qualidade nas organizações, tenderem a encontrar-se ligadas por sua vez a um incremento nos custos dentro das organizações. Esta visão, é parcialmente verdadeira, mas é inexata e incompleta. Como Juran (1999) refere, o aumento de qualidade dos produtos requer por vezes um investimento. Apesar de esse investimento pretender aumentar a rentabilidade através do aumento da a satisfação do cliente final, de facto um aumento de qualidade é mais dispendioso neste sentido. Contudo, um aumento de qualidade numa organização significa que existe uma determinada desvinculação das não conformidades. Ou seja, deixam de existir certos erros que poderão levar a reprocessamentos sucessivos do produto, falhas de trabalho no terreno, insatisfação ou mesmo queixas dos próprios clientes, entre outras coisas. Nesta perspetiva o significado de qualidade encontra-se orientado para os custos sobre este pressuposto um maior nível de qualidade, de um modo geral, leva a custos menores.

Diversos autores contribuíram de grande forma para a evolução de conceito de Qualidade. Contributo esse de valor inestimável uma vez que em mercados altamente competitivos como são os mercados atuais, a excelência no campo da qualidade poderá ser um fator um fator decisivo para o sucesso das organizações.

2.4. Gestão pela Qualidade Total (TQM)

Distintas fontes da literatura científica destacam a forma como as organizações tendem a prestar atenção e procuram desenvolver o seu desempenho. A UI EQUIPAR insere-se nesse conjunto pelo esforço que tem feito na melhoria da Qualidade nos últimos anos e é nesse sentido que se vai abordar brevemente esta temática.

Para desenvolver este tipo de cultura nas organizações podem ser aplicados diversos conceitos e/ou métodos comumente conhecidos como “Qualidade Total” ou “Gestão da Qualidade Total”. Juran (1999) refere, neste contexto, que se pode entender “Gestão pela qualidade total” enquanto um conjunto vasto de filosofias, conceitos, métodos e ferramentas que são utilizadas em todo o mundo para gerir a qualidade. Este tipo de técnicas tem levado as empresas, hodiernamente, a dar valor à qualidade e à gestão do negócio. Tem levado as mesmas a repensarem como se encontram organizadas, como se gerem a elas mesmas e até mesmo os negócios em que se devem inserir (Juran, 1999).

Ainda segundo Juran (1999), tendo em conta que a qualidade passou a significar a capacidade de exceder as necessidades e as expectativas dos clientes, em acréscimo à capacidade de manter conformidade para com as especificações e os requisitos, foram-se tornando universais quatro objetivos quando se aplica a gestão pela qualidade total:

- Redução de custos
- Incremento de receitas
- Clientes satisfeitos
- Colaboradores com poder autónomo de decisão e ação

Apesar destes objetivos é importante que as organizações façam análises introspectivas e retrospectivas de forma a analisarem e aperfeiçoarem os seus alicerces, fortalecendo as suas fundações para poderem desenvolver-se enquanto unidades mais robustas.

Nomeadamente, existem 3 conceitos fundamentais (Juran, 1999). O foco no cliente, como já foi referido acima, é imperativo para se atingir o sucesso, uma vez que se encontra comprovado que as empresas ultrapassam a satisfação e retenção dos clientes para atingir a lealdade dos mesmos, e as organizações passam a concentrar-se nesse objetivo estratégico. A melhoria contínua, filosofia essa que veio transformar a forma como as organizações encaram a mudança, permitindo muitas vezes ganhos de recursos ou cortes de desperdícios bastante significativos. Por fim, o valor de cada colaborador. A atenção a este último ponto tem sido crucial em muitas organizações para reorganizarem toda a forma como pensam e agem, tirando o maior propósito possível do seu capital humano.

Ainda segundo Juran (1999), existem três processos críticos para executar a gestão da Qualidade. É importante ter em mente que estes três processos, presentes na imagem que se segue e que são explanados em seguida, se encontram profundamente interrelacionados.




Figura 2.1 - Trilogia de Juran. Fonte: Juran (1999)

- **Planeamento da Qualidade** – Para executar este primeiro passo é necessário primeiramente identificar quais são os clientes alvo e quais são as suas necessidades. A partir do momento em que este primeiro passo está concluído é possível delinear os produtos ou serviços que satisfaçam essas mesmas necessidades. A partir daqui é que se muda o foco para o lado operacional, que tem a responsabilidade de conduzir as operações necessárias para que o processo decorra como é suposto, os bens ou serviços sejam efetivamente produzidos e os clientes sejam por fim satisfeitos. Existem algumas ferramentas mais técnicas utilizadas no planeamento da qualidade, tais como o desenho de experiências que será explicado, mais adiante, no intuito deste estudo. Note-se ainda, quanto a este processo, que independentemente da forma minuciosa com que estes métodos e ferramentas sejam aplicados, a maioria dos processos não é perfeito. Isto significa que existe sempre algum tipo de desperdício associado ao processo (e.g. tempo, erros, reprocessamento, trabalhos de valor não acrescentado). Contudo, apesar de existirem desperdícios que são por vezes inevitáveis, passando primeiro pela implementação de sistemas de controlo de qualidade é possível procurar por oportunidades que permitam melhorar significativamente os níveis de qualidade atingidos e/ou reduzir o desperdício.
- **Controlo da Qualidade** – A componente mais técnica ligada a este processo será explicada mais à frente, no momento em que for explorado o tema “SPC”, porém é importante que fique claro a partir deste momento para o leitor que é através deste processo que as forças operacionais podem avaliar e minimizar o desperdício, nomeadamente apoiando-se em 5 princípios básicos:
 - Definição clara de qualidade
 - Alvo / objetivo
 - Uma métrica de performance
 - Uma forma de avaliar essa unidade de medida
 - Delinear uma forma de agir sobre o processo, caso seja necessário
- **Melhoria da Qualidade** – Raciocinando a partir do último princípio referido no processo de controlo da qualidade é importante sublinhar que os processos destacados até ao momento ocorrem todos apenas ao nível de planeamento de qualidade. Isto significa que existe uma necessidade de tomar deliberadamente ações concretas para aumentar os níveis de qualidade e passar do planeamento ou projeto para o “terreno”. Juran (1999) cita Deming (1982) nesta matéria através da alegoria “Apagar fogos num hotel não torna o hotel melhor”. Isto significa que não basta descobrir as causas especiais de variação e retirar as mesmas, uma vez que isto não impede que as causas voltem a ocorrer e é necessário que as organizações tomem medidas para que este tipo de conduta não ocorra e existam processos de melhoria de qualidade nas organizações direcionados para a uma boa performance a longo prazo das mesmas.

2.5. Desenho de Experiências (DOE)

A capacidade de observação é uma característica fundamental à prática de engenharia industrial. Através desta capacidade torna-se muito mais simples aprender profundamente sobre qualquer sistema e analisar onde e encontram as mais prováveis e expressivas causas de perturbações num sistema (e.g. processos de fabrico). Contudo, Montgomery (2013a) refere que para perceber o que acontece num dado sistema quando submetido a certas variações no *input*, como por exemplo alterações de parametrizações de um equipamento industrial, torna-se necessário ir além da contemplação do sistema e torna-se necessário agir sobre o mesmo e proceder a alterações de determinados fatores. Ou seja, de forma a entender na prática as relações causa-efeito presentes no sistema torna-se necessário proceder a alterações à entrada do sistema e interpretar os *outputs* obtidos. Ou seja, como uma vez mais Montgomery (2013a) expressa, é necessário realizar experiências sobre o sistema.

O Desenho de experiências, frequentemente aludido pela sigla inglesa *DOE – Design Of Experiments*, também é comumente conhecido como Plano/Planeamento de experiências ou ainda como conceção de experiências (Pereira e Requeijo, 2012). Esta metodologia teve a sua génese com Ronald A. Fisher nos anos 1920-1930, que iniciou o seu desenvolvimento na *Agricultural Experimental Station* de Rothamsted (Inglaterra) tendo em vista uma teoria científica de experimentação que tivesse aplicação na área agrícola. Apresenta-se enquanto uma técnica que se sobrepõe ao método usualmente utilizado de variar “um fator de cada vez”, sendo mais eficiente ao recorrer a métodos estatísticos para planejar, executar e analisar os resultados obtidos.

Este procedimento permite identificar quais são os fatores (controláveis) que influenciam significativamente os *outputs* das características da qualidade, ou indicadores de desempenho, referentes a um dado processo ou produto, que se tratam essencialmente de informações quantificáveis que permitem caracterizar o processo globalmente, seguir o processo e estimar o seu desempenho futuro. Permite simultaneamente verificar quais são os níveis adequados de parametrização a que cada um desses fatores se deve encontrar para que o produto final, ou o processo em análise, seja o mais resiliente possível a fatores de ruído (Pereira e Requeijo, 2012) e o processo se desenrole com uma variabilidade menor. É importante destacar que na versão moderna do DOE, recorrendo a métodos estatísticos e algébricos, tornou-se possível que o DOE seja aplicado eficientemente, recorrendo ao menor número de ensaios possível sem que haja uma perda de informação expressiva.

Existem alguns conceitos subjacentes à noção de desenho de experiências que vão ser expostos em seguida para um melhor entendimento das temáticas aqui referidas.

Em primeiro lugar, segundo Pereira e Requeijo (2012) pode-se pensar numa dada experiência (ou ensaio) que terá lugar enquanto um teste, no qual se alteram as variáveis ou parâmetros do processo, conhecidos nesta metodologia como fatores, que tem como fim caracterizar as alterações que poderão ocorrer nas características da unidade experimental e apurar as fontes dessas alterações. Montgomery (2013a) refere que uma experiência pode ser vista como uma série de *runs* ou testes/ensaios que servem o propósito supracitado. A unidade experimental em si trata-se efetivamente da entidade na qual são feitas as medições das características em causa (Pereira e Requeijo, 2012).

Por sua vez, segundo Montgomery (2013a), e tal como a Figura 2.2 demonstra, as fontes de variação numa dada experiência podem ser divididas em dois grupos:

- Fatores controláveis: São os fatores que para os efeitos da experiência podem ser selecionados/utilizados
- Fatores não controláveis: São fatores cujos efeitos serão possivelmente retirados através dos princípios da aleatoriedade ou do efeito de blocos, que serão explicados adiante, ou simplesmente poderão ser tornados numa constante enquanto a experiência está a decorrer.




Figura 2.2 - Modelo geral de um processo ou sistema. Adaptado de: Montgomery (2013a)

Montgomery (2013a) refere ainda a existência dos *nuisance factors* que o mesmo separa entre controláveis, não controláveis ou de ruído. Estes *nuisance factors* são factores que podem influenciar a resposta, contudo são fatores nos quais os investigadores não se encontram necessariamente interessados, e.g. hipoteticamente, para executar uma experiência é necessário utilizar dois lotes de uma determinada matéria-prima, pois um lote não tem matéria-prima suficiente para executar todos os testes. Nesse caso, poderia haver diferenças entre os lotes por diversos motivos, como por exemplo serem de fornecedores diferentes ou criados de alguma forma sobre condições diferentes, o que confere uma determinada variabilidade extra, indesejada, à matéria-prima quando vista como um todo e portanto, quem realiza a experiência

não está necessariamente interessado neste efeito. Assim sendo, os lotes de matéria-prima podem ser vistos como *nuisance factors*. Quando este caso ocorre pode ser aplicada uma técnica conhecida como *blocking*, que é uma técnica utilizada para melhorar a precisão com que as comparações entre fatores que são considerados relevantes são feitas. Aplicando ao caso dos *nuisance factors*, mais concretamente, é utilizado para reduzir ou eliminar os efeitos da variabilidade que existem devido a estes fatores. Contudo, quem realiza a experiência poderia estar interessado em estudar o efeito do fator matéria-prima, mesmo não sendo possível manter a sua variabilidade sobre controlo. Neste caso, segundo Pereira e Requeijo (2012) pode considerar-se que a matéria-prima é um fator de ruído (fatores estes habitualmente não controláveis) e cada um destes lotes representa um nível distinto do fator de ruído matéria-prima.

Cada fator por sua vez pode assumir distintos valores, quantitativos ou qualitativos, que no contexto do DOE são comumente conhecidos como níveis, ou ainda como tratamentos (Pereira e Requeijo, 2012).

Cada fator produz um designado efeito quando alterado, ou seja, quando troca de nível. Este efeito na prática pode ser pensado como o desvio da média geral que o mesmo provoca no output (Montgomery, 2013a).

O objetivo óbvio ao executar estas alterações é estudar o resultado das experiências. Estes resultados são denominados de resposta, que no contexto da Gestão da Qualidade é compreendida como a característica da Qualidade que os investigadores pretendem otimizar, preferencialmente quantificável (Pereira e Requeijo, 2012). Trata-se, em termos simples, de uma variável dependente.

Sublinha-se que um determinado DOE poderá envolver mais do que um fator controlável. Se esta situação se verificar passamos a referir-nos a uma determinada combinação de níveis, que não é mais do que o conjunto de todos os níveis existentes, de todos os fatores, numa determinada experiência. Por sua vez, o conjunto de todas as combinações de níveis para os quais a experimentação é possível é denominado de região experimental ou ainda espaço experimental (Pereira e Requeijo, 2012).

Existem três princípios bastante importantes quando se aplica o DOE, dos quais os dois primeiros são considerados fundamentais na literatura e serão analisados adiante: a replicação, a realização aleatória de experiências e o previamente referido *blocking*.

A replicação no fundo trata-se da repetição de um dado ensaio, ou mesmo de uma dada experiência mantendo sempre as condições semelhantes (Pereira e Requeijo, 2012). Segundo Montgomery (2013a) estas repetições são executadas de forma independente para cada combinação de fatores. Montgomery (2013a) menciona ainda que a aplicação deste princípio potencia duas utilizações relevantes para quem realiza a experiência. A primeira é que a partir do momento em que se aplica a replicação torna-se possível obter uma estimativa do erro experimental, o que torna possível verificar se as diferenças existentes nos dados são de facto consideradas estatisticamente significativas. Em segundo lugar, no caso de se utilizar a média

experimental para estimar a resposta de um determinado fator, torna-se possível obter uma estimativa mais precisa deste valor.

Essencialmente, a aplicação de replicação permite a quem realiza as experiências executar inferências que sejam satisfatórias sobre os objetos de estudo. Sublinha-se o facto de existir uma diferença entre os conceitos de replicação e repetição de medições. A repetição de medições é representativa das diferenças existentes dentro de um determinado teste ou ensaio e, portanto, da sua variabilidade intrínseca, ao passo que a replicação está associada às fontes de variabilidade entre os ensaios e potencialmente poderá representar também a fonte de variabilidade dentro dos próprios ensaios, sendo, portanto, um conceito distinto e potencialmente mais abrangente. Posto isto “[...] as réplicas não são os valores de uma resposta medidos numa mesma experiência, mas sim os valores obtidos por replicação dessa experiência.” (Pereira e Requeijo, 2012, p.153).

A aleatoriedade, por sua vez, é referida diversas vezes na literatura como se se tratasse da pedra basilar que sustenta a utilização de métodos estatísticos no desenho experimental. Montgomery (2013a) associa a aleatoriedade ao tratamento que se concede ao material experimental, no que diz respeito à sua alocação, e à ordem com que os ensaios (individuais) são realizados. Para a aplicação da vertente estatística ser válida é imperativo que as observações realizadas e/ou os seus erros apresentem distribuições aleatórias independentes. Sublinha-se que garantir este princípio também ajuda a eliminar potenciais efeitos existentes de quaisquer fatores estranhos à experimentação que possam existir.

No que diz respeito à confluência dos métodos estatísticos com o desenho experimental torna-se essencial que exista uma abordagem sistemática que caucione resultados positivos, passando pelo esclarecimento de todos os membros envolvidos na experimentação, i.e. garantir que todos os membros envolvidos tenham ideia clara, antes da experimentação ocorrer, do que é para ser estudado em concreto, como é que os dados vão ser recolhidos e pelo menos uma ideia geral de como é que os dados vão ser analisados. Existem alguns passos importantes que podem e devem ser tomados. Vão ser listados em seguida estes mesmos passos, de modo sequencial, tendo como base algumas guias fornecidas por Montgomery (2013a).

- 1. Reconhecimento e declaração do problema.** Apesar deste primeiro passo poder parecer óbvio, quando se tenta fazer uma aplicação prática pode não ser fácil perceber ou reconhecer que a resolução de um determinado problema requer experimentação. A própria declaração concreta de um determinado problema a ser resolvido pode não ser de fácil obtenção. Normalmente, é necessária (e recomendada) uma abordagem de equipa, constituída com membros das diferentes áreas envolvidas. Elaborar uma lista de problemas específicos que se pretendem resolver ou de questões a serem respondidas e manter o foco mental nos objetivos gerais da experimentação poderão ser uma solução para este tipo de problemas.
- 2. Seleção da variável de resposta.** Partindo um pouco do ponto anterior e constatando uma vez mais algo que é potencialmente classificado como óbvio, ao selecionar a variável de

reposta é necessário garantir que através da variável escolhida será possível obter informação útil acerca do processo ou sistema em estudo. Deve ser definido à *priori* como é que uma ou as várias respostas em causa devem ser medidas e lidar com potenciais problemas que possam surgir, tais como a calibração dos sistemas de manutenção (e.g. como e quando será feita). Outra questão a ter em conta é se será mais proveitoso realizar várias medições e usar um valor médio para cada ensaio em vez de uma única amostra por ensaio. Este tipo de questões deve ser pensado antes de executar a experiência. Fisher (1937) refere que ao propor e analisar se um dado desenho de experiências é adequado, é necessário prever todos os resultados possíveis da experiência e decidir, sem ambiguidade, qual a interpretação a ser retirada de cada um desses resultados.

3. **Seleção dos fatores e definição dos níveis a serem utilizados.** Normalmente a definição dos moldes destes dois parâmetros é realizada em simultâneo durante a aplicação prática. Fazendo a ligação ao que já foi dito anteriormente, quando o responsável pela experiência se encontra a ponderar que fatores deve utilizar, estes fatores podem ser classificados como potenciais fatores a serem utilizados no desenho ou enquanto *nuisance factors*, sendo os fatores potenciais a serem utilizados no desenho aquele que quem experimenta poderá ir alterando (os níveis) no decorrer da experiência. O condutor da experiência é quem deve definir os intervalos sobre os quais cada fator deve variar e também os níveis sobre os quais cada ensaio irá decorrer. O conhecimento do condutor da experiência e/ou dos que intervêm ou beneficiaram da mesma é determinante neste ponto. O diagrama de Ishikawa poderá uma ferramenta valiosa neste ponto, podendo ajudar a organizar alguma da informação inicial e preparar da melhor forma a experiência que irá ter lugar.
4. **Escolha do desenho de experiências.** Se os passos anteriores forem executados da forma correta, este passo torna-se relativamente mais acessível. A escolha do desenho de experiências está ligada à definição do número de réplicas a realizar, definição da ordem dos ensaios a realizar, tanto da experiência “teste”, se for realizada, como da experiência principal (ordem idealmente aleatória, como já foi referido), se se aplicar a técnica de blocos ou se existem restrições à ordem aleatória dos ensaios. Para executar este passo já existem bastantes *softwares* que ajudam a programar e definir algumas destas variantes.
5. **Realização da experiência.** Enquanto se conduz a experiência é essencial que se monitorize o processo e execute o planeamento de forma minuciosa. Caso contrário é provável que os erros na execução tenham lugar e os resultados obtidos poderão não ser válidos. Montgomery (20123) refere Coleman e Montgomery (1993) ao afirmar que fazer alguns ensaios piloto normalmente antes da experiência principal normalmente é bastante útil, uma vez que estes ensaios piloto fornecem informações sobre a robustez geral de todas as variáveis que envolvem a realização da experiência e serve de oportunidade para praticar, ganhar uma ideia do erro experimental espectável e realizar alguns ajustes que possam ser necessários.
6. **Análise estatística dos dados obtidos.** Devem ser aplicados métodos estatísticos para que seja possível retirar conclusões objetivas em vez de conclusões opináticas. É importante

referir uma vez mais que existem variados *softwares* que permitem realizar as análises necessárias, por exemplo através do recurso a métodos gráficos ou através da criação de modelos empíricos.

7. **Conclusões e recomendações.** Depois da análise dos dados ser realizada, o responsável pelas experiências deve apresentar os resultados e as conclusões de uma forma prática e deve recomendar as medidas a serem tomadas. O recurso a métodos gráficos é altamente recomendado nesta fase. Idealmente devem ser executados ensaios de confirmação de forma a validar os resultados obtidos.

É importante também tocar nalguns pontos que dizem respeito a todas as ocasiões em que se aplica o desenho de experiências. Em primeiro lugar é importante estabelecer que o processo de experimentação, quando executado da forma correta, é um processo iterativo e uma parte importante do processo de aprendizagem sobre quaisquer sistemas. Isto significa que dificilmente se alcançará algum resultado positivo apenas com uma experiência, *i.e.*, muito dificilmente uma só matriz experimental conduzirá a resultados que tenham algum valor benéfico. Montgomery (2013a) refere que se comete um erro quando se planeia apenas uma grande e profunda experiência no início de um estudo. Os resultados de um determinado estudo ajudarão a ditar as condições em que o seguinte se irá desenrolar, ajustando as parametrizações da experiência para que se foque cada vez mais naquilo que se pretende encontrar. Assim sendo, uma utilização correta do desenho de experiências consiste em aplicar esta técnica de forma sequencial. Outro facto importante de sublinhar é que a utilização de resultados já existentes na empresa tende a inviabilizar os estudos uma vez que normalmente não existem garantias que as experiências anteriores tenham sido executadas de uma forma cientificamente correta, ou mesmo que as medições foram recolhidas de forma igualmente correta. É importante constatar também que um dado desenho experimental (e a sua execução) não têm necessariamente de ser complexos de forma a serem bem-sucedidos. Pelo contrário, na literatura desta matéria é referido por diversas vezes que desenhos mais simples desde que sejam minuciosamente planeados e executados tendem a conduzir a conclusões muito valiosas e na maior parte das vezes surpreendentes.

2.5.1 Desenho Fatorial (Dois Fatores a Vários Níveis)

Uma das aplicações mais acessíveis do desenho de experiências está ligada aos casos em que o desenho envolve apenas dois fatores. Como foi previamente referido, cada um destes fatores poderá ter múltiplos tratamentos. Acrescenta-se agora que um determinado fator A terá a níveis e um determinado fator B terá b níveis. O tipo de planeamento que vai ser apresentado em seguida diz-se completo uma vez que se efetuarão ensaios relativamente a todas as combinações possíveis dos dois fatores, *i.e.*, serão estudadas um total de $a \times b$ combinações e serão realizados $a \times b \times n$ ensaios, sendo n o número de replicações que quem conduz a

experiência decidiu realizar. Sublinha-se neste ponto uma vez mais a importância da aleatoriedade na realização dos ensaios.

Tabela 2.1 - Arranjo geral de dois fatores a vários níveis, Fonte: Montgomery (2013a)

		Factor <i>B</i>			
		1	2	. . .	<i>b</i>
Factor <i>A</i>	1	$y_{111}, y_{112},$ \dots, y_{11n}	$y_{121}, y_{122},$ \dots, y_{12n}		$y_{1b1}, y_{1b2},$ \dots, y_{1bn}
	2	$y_{211}, y_{212},$ \dots, y_{21n}	$y_{221}, y_{222},$ \dots, y_{22n}		$y_{2b1}, y_{2b2},$ \dots, y_{2bn}
	\vdots				
	<i>a</i>	$y_{a11}, y_{a12},$ \dots, y_{a1n}	$y_{a21}, y_{a22},$ \dots, y_{a2n}		$y_{ab1}, y_{ab2},$ \dots, y_{abn}

As respostas, que são representadas através da letra *Y* darão origem a um quadro similar ao da Tabela 2.1. A partir deste modelo de efeitos fixos torna-se possível definir o modelo matemático e realizar a análise de variância.

A soma de todas as observações é dada por:

$$Y \dots = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n y_{ijk} \quad (2.1)$$

Isto significa que o somatório das respostas dadas por um dado nível do fator *A* e do fator *B* será dado respetivamente por:

$$Y_{i..} = \sum_{j=1}^b \sum_{k=1}^n y_{ijk} \quad (2.2)$$

$$Y_{.j.} = \sum_{i=1}^a \sum_{k=1}^n y_{ijk} \quad (2.3)$$

Seguindo a mesma linha de raciocínio, as respetivas médias de cada fator, assim como a média geral serão dadas pelas seguintes expressões:

$$\bar{Y}_{i..} = \frac{Y_{i..}}{bn} \quad (2.4)$$

$$\bar{Y}_{.j.} = \frac{Y_{.j.}}{an} \quad (2.5)$$

$$\bar{Y} \dots = \frac{Y \dots}{N} \quad (2.6)$$

Note-se que muitas vezes o objetivo de uma dada investigação não é necessariamente estimar um dado parâmetro, mas sim decidir qual é a ilação correta a extrair de cada um desses parâmetros, ou da interação entre eles, entre duas hipóteses distintas. O método que permite

realizar esta inferência estatística denomina-se teste de hipóteses. Esta técnica alia-se ao facto de se pretender através da análise ao modelo de efeitos fixos caracterizar os diversos níveis e combinações de níveis de forma proceder à sua comparação, através da estimação dos respetivos valores esperados, e averiguar quais são os efeitos correspondentes a cada nível que podem ser considerados significativamente diferentes de zero, estatisticamente falando (Pereira e Requeijo, 2012). A partir deste momento os efeitos dos dois fatores A e B poderão aparecer representados por τ e β e a sua interação por γ .

Sendo ε uma variável normal e independentemente distribuída com média nula e variância σ^2 o modelo matemático em causa é dado por:

$$Y_{ijk} = \mu + \tau_i + \beta_j + \gamma_{ij} + \varepsilon_{ijk} \quad (2.7)$$

O funcionamento e outras variantes do teste de hipóteses serão explorados mais à frente no capítulo relacionado com outros conceitos estatísticos, contudo frisa-se que as hipóteses nulas e alternativas e a serem testadas são:

$$H_0: \tau_1 = \tau_2 = \dots = \tau_a \quad (2.8)$$

$$H_1: \text{Pelo menos um } \tau_j \neq 0$$

$$H_0: \beta_1 = \beta_2 = \dots = \beta_a \quad (2.9)$$

$$H_1: \text{Pelo menos um } \beta_j \neq 0$$

$$H_0: \gamma_{ij} = 0 \text{ para qualquer par } (i, j) \quad (2.10)$$

$$H_1: \text{Pelo menos um } \gamma_{ij} \neq 0$$

2.5.2 Análise de Variância do Modelo de Efeitos Fixos

A análise de variância pode ser compreendida enquanto uma técnica que, fazendo recurso à estatística, permite a comparação entre parâmetros de duas populações distintas. A partir desta análise é possível ligar a variabilidade existente nos dados a cada um dos diversos componentes responsáveis por causar essa variabilidade e a partir de aqui determinar quais são os fatores significativos. Esta análise de variância estruturada é comumente conhecida como ANOVA (Pereira e Requeijo, 2012).

Para o modelo exposto, a variação total presente nos dados experimentais é dada por:

$$ss_T = \sum_{i=1}^a \sum_{j=1}^b \sum_{k=1}^n Y_{ijk}^2 - \frac{(Y_{...})^2}{abn}, \text{ com } (abn-1) \text{ graus de liberdade} \quad (2.11)$$

Por sua vez, a variação associada a cada um dos fatores será dada respetivamente por:

$$SS_A = \sum_{i=1}^a \frac{Y_{i.}^2}{bn} - \frac{(Y_{...})^2}{abn}, \text{ com } (a-1) \text{ graus de liberdade} \quad (2.12)$$

$$SS_B = \sum_{j=1}^b \frac{Y_{.j}^2}{an} - \frac{(Y_{...})^2}{abn}, \text{ com } (b-1) \text{ graus de liberdade} \quad (2.13)$$

Já a variação causada pela interação entre os fatores A e B é calculada por:

$$SS_{AB} = \sum_{i=1}^a \sum_{j=1}^b \frac{Y_{ij}^2}{n} - \frac{(Y_{...})^2}{abn} - SS_A - SS_B, \text{ com } (a-1)(b-1) \text{ graus de liberdade} \quad (2.14)$$

Por fim a variação residual, comumente intitulada de erro, é calculada por:

$$SS_{Erro} = SS_T - SS_A - SS_B - SS_{AB}, \text{ com } (ab)(n-1) \text{ graus de liberdade} \quad (2.15)$$

O quociente entre as variações dos fatores e interação e os respectivos graus de liberdade permite calcular os desvios quadráticos médios associados. Ou seja:

$$MS_A = \frac{SS_A}{a-1} = \sigma^2 + \frac{bn \sum_{i=1}^a \tau_i^2}{a-1} \quad (2.16)$$

$$MS_B = \frac{SS_B}{b-1} = \sigma^2 + \frac{an \sum_{j=1}^b \beta_j^2}{b-1} \quad (2.17)$$

$$MS_{AB} = \frac{SS_{AB}}{(a-1)(b-1)} = \sigma^2 + \frac{n \sum_{i=1}^a \sum_{j=1}^b \gamma_{ij}^2}{(a-1)(b-1)} \quad (2.18)$$

$$MS_{Erro} = \frac{SS_{Erro}}{ab(n-1)} = \sigma^2 \quad (2.19)$$

Note-se que ao realizar a ANOVA a significância de cada um dos fatores será verificada através do quociente entre cada uma das variâncias calculadas e a variância do erro. Pode verificar-se em seguida, na Tabela 2.2, uma ilustração demonstrativa dos cálculos típicos da ANOVA associada a este tipo de desenho.

Tabela 2.2- ANOVA

Fonte de Variação	SS	g.l.	MS	Fo
Factor A	SS _A	(a-1)	SS _A /(a-1)	MS _A /MS _{Erro}
Factor B	SS _B	(b-1)	SS _B /(b-1)	MS _B /MS _{Erro}
Interacção AB	SS _{AB}	(a-1)(b-1)	SS _{AB} /((a-1)(b-1))	MS _{AB} /MS _{Erro}
Erro	SS _{Erro}	(ab)(n-1)	SS _{Erro} /(ab(n-1))	-
Total	SS _{Total}	(abn-1)	-	-

2.5.3 Análise de Resíduos

No desenho de experiências com dois fatores a vários níveis são as médias das repostas obtidas para cada combinação existente dos níveis dos fatores que contribuem para os valores previstos

para cada combinação de fatores. A partir daqui é possível calcular os chamados resíduos, que não são mais do que a diferença entre os valores observados e os valores previstos para uma dada variável Y que está a ser estudada (Pereira e Requeijo, 2012).

$$e_{ijk} = y_{ijk} - \hat{y}_{ijk} \quad (2.20)$$

Existem pressupostos associados ao modelo matemático e análise de variância que é importante garantir, de forma a que quem conduz a investigação possa garantir que os resultados são representativos do sistema em análise. Estes pressupostos visam garantir que os erros são independentes e normalmente distribuídos com média nula e variância constante (Pereira e Requeijo, 2012). Isto significa que a verificação da validade dos pressupostos referentes ao modelo e à análise de variância deve sempre ser realizada. A verificação dos pressupostos deve incluir os seguintes aspetos:

- **Verificação da Normalidade.** Esta análise poderá ser executada realizando um simples histograma dos resíduos. Embora seja algo subjetiva, esta é uma forma prática de fazer a análise dos resíduos, passando pela construção do gráfico, usando o papel de probabilidades da distribuição normal e analisando se os resíduos se dispõem aproximadamente em linha reta. Se este facto se verificar pode-se concluir que o pressuposto da Normalidade é razoavelmente satisfeito. Sublinha-se que a existência desvios moderados da normalidade não devem ser entendidos como fatores preocupantes. Para executar o gráfico devem ser seguidos os seguintes passos:
 - Ordenar os dados por ordem crescente de grandeza
 - Atribuir o número de ordem que indica a posição ou o nível de cada observação
 - Calcular os valores das frequências acumuladas observadas, em percentagem, a serem representados no gráfico, podendo para esse efeito ser utilizada a seguinte expressão:

$$Pi = \frac{i-0.5}{n} * 100 \quad (2.21)$$

Após este cálculo, representam-se os valores calculados num gráfico e caso os resíduos se assemelhem a uma distribuição normal irão dispor-se em torno de uma reta no gráfico, como se poderá verificar na Figura 2.3.

Independência dos dados. Analisar os dados graficamente dispondo os mesmos por ordem cronológica pode ser bastante útil ajudando a detetar a existência de fortes correlações que possam existir entre os resíduos. Se este pressuposto for violado, existe uma probabilidade de existir um problema sério e difícil de corrigir, portanto é fulcral que se recolham os dados escrupulosamente para prevenir, de raiz, que este problema surja.

Garantir a aleatoriedade da experiência é um passo importante para garantir o princípio da independência dos dados. A destreza de quem executa a experiência, ou os próprios objetos alvo da experiência poderão mudar à medida que a experiência progride. Isto muitas vezes conduz a que exista uma mudança na variância ao longo do tempo, o que por sua vez poderá também constituir um potencial um problema grave (Montgomery, 2013a).

Uma vez mais, recorrer a um simples método gráfico tem demonstrado ser o método mais prático para avaliar a independência devido ao facto de ser um método de análise visual e rápido, que permite retirar ilações rapidamente.




Figura 2.3 - Probabilidades da Distribuição Normal. Adaptado de: Montgomery 2013^a

Colocando os resíduos em função da ordem aleatória pela qual as experiências foram efetuadas é possível verificar visualmente se os resíduos se dispõem de forma aleatória, *i.e.*, não demonstram qualquer tendência especial (Pereira e Requeijo, 2012).

Existem outros tipos de testes que podem ser aplicados de forma a apurar a independência dos dados ou inexistência da mesma de forma mais objetiva. Tratam-se da função de autocorrelação e função de autocorrelação parcial que serão expostos adiante no âmbito do controlo estatístico de processo.

- **Homogeneidade da variância.** Seguindo a mesma linha de raciocínio aplicada até ao momento, segundo Montgomery (2013a), se a conceção do modelo for a correta e se os pressupostos forem satisfeitos então os resíduos não irão apresentar nenhum padrão ou estrutura em particular, tal como é demonstrado na Figura 2.4. Isto significa que não estão relacionados com qualquer variável, o que inclui os valores previstos para as respostas do desenho de experiências em causa. A construção de um gráfico demonstra ser uma vez o método mais simples pois caso o pressuposto da variância ser constante não seja fortemente violado, o gráfico não irá apresentar qualquer estrutura ou padrão em particular. Ao aplicar este método no terreno é comum verificar que a variância aumenta ou diminui com os valores das observações (ou da sua média), o que se traduz num gráfico em forma de funil (Pereira e

Requeijo, 2012). Isto poderá acontecer por exemplo nos casos em que a variância das observações aumenta à medida que a magnitude das observações também aumenta.




Figura 2.4 - Resíduos e ordem das experiências. Fonte: Montgomery, 2013a

Isto poderá acontecer pelo facto do erro ou o ruído de fundo na experiência representar sempre uma determinada percentagem constante da dimensão da observação, como é o caso que se verifica em muitos equipamentos de medição em que o erro é uma percentagem da escala de leitura (Montgomery, 2013a). Recolher amostras de tamanho igual sempre que possível ajuda a reduzir este tipo de efeitos.

O facto de se verificarem desigualdades na variância também poderá ocorrer ocasionalmente no gráfico dos resíduos em função dos valores previstos, por exemplo ao aumentar ao longo do tempo, também poderá estar relacionada com a fadiga do operador ou do próprio objeto de estudo, de stress acumulado em determinados equipamentos, mudanças nas propriedades dos materiais ou outro tipo de causas semelhantes.

Pode ser verificado através da Figura 2.4, um caso exemplar em que dispondo correspondentemente os valores dos resíduos obtidos no eixo das ordenadas e os valores previstos no eixo das abcissas não se verificam quaisquer tendências ou padrões não aleatórios, uma vez que a mancha verificada não apresenta qualquer estrutura em particular, indicando então que tal como nos exemplos anteriores não existe qualquer indicio de violação do pressuposto, que neste caso se trata do pressuposto da homogeneidade da variância.




Figura 2.5 - Resíduos e valores previstos. Fonte: Montgomery, 2013^a

2.5.4 Tomada de Decisão

É importante frisar dois pontos acerca do desenho de experiências. O primeiro é que para se tomar uma decisão, será necessário definir primeiro qual é que é o foco de melhoria. Na maior parte dos casos passará por um de dois objetivos, diminuição da variabilidade do processo ou diminuição da distância da sua tendência central a um determinado *target*. É importante antes de executar a análise dos dados qual será o objetivo, pois o resultado da análise que se faz ao DOE para além de por vezes poder ser subjetiva, poderá variar consoante o objetivo que se pretende atingir. O segundo ponto, que apoia nesta decisão, prende-se com as superfícies de resposta, obtidas a partir das relações entre os níveis. Esta ferramenta poderá ser utilizada sob a forma de gráfico 2D ou 3D. A ferramenta, quando utilizada sobre a sua vertente 2D é habitualmente denominada de gráfico de contorno. Este gráfico obtém-se através da projeção da superfície de resposta num gráfico bidimensional (Pereira e Requeijo, 2012). Através deste tipo de gráficos tipicamente é possível analisar que combinações de níveis dos fatores é que conduzem a um determinado valor da resposta, o que é fundamental em momentos de tomadas de decisão acerca de melhoria contínua de desempenho com custos tão baixos quanto seja possível (Pereira e Requeijo, 2012)

2.5.5 Considerações Finais Acerca do DOE

Ao não efetuar a análise de resíduos para verificar a validade dos pressupostos feitos na análise de variância incorre-se num risco sério de se retirarem conclusões erradas sobre os dados da experimentação. Atualmente esta tarefa já se encontra bastante facilitada face aos recursos informáticos modernos, tornando-se bastante simples executar estas análises.

Caso os pressupostos da Normalidade e da homogeneidade da variância não seja satisfeito poderá ser necessário proceder a uma transformação dos dados originais. É importante frisar que caso os resíduos se encontrem auto-correlacionados nesta fase é aconselhável executar uma nova execução de todas as experiências.

Após a recolha dos dados e feita a análise descrita até ao momento é necessário interpretar os resultados, consoante os fatores ou interações que tenham sido consideradas significativas ou não significativas no sistema em escrutínio. Esta interpretação depende em primeiro lugar do objetivo que se pretende atingir. O objetivo normalmente será maximizar ou minimizar os valores de uma certa variável de resposta ou então poderá ser aproximar esses valores de um dado valor ótimo denominado alvo ou *target* quando referido na língua inglesa. Colocado objetivo serão então escolhidos os melhores níveis para os fatores ou interações consideradas significativas. Todos os fatores ou interações não significativas deverão operar sobre os níveis mais económicos, isto é, que representem menor custo para o sistema ou organização a que o processo em estudo pertence.

2.6. Controlo Estatístico Para Dados Independentes

2.6.1 Controlo Estatístico de Processo Tradicional

É imperativo atribuir enorme importância na satisfação dos clientes finais, alcançada através da melhoria de um determinado produto ou serviço que está a ser oferecido. O facto de um dado processo ser capaz de ir de encontro aos requisitos dos clientes, ou mesmo excedê-los tem um grande papel neste contexto (Mitra, 2008). Montgomery (2013b) refere ainda que um processo deve ser capaz de operar com a menor variabilidade possível em torno de um objetivo pré-determinado. O controlo estatístico de processo vem responder precisamente a esta questão. Frequentemente aludido por *statistical process control* (SPC), o controlo estatístico de processo trata-se de uma ferramenta poderosa utilizada para atingir a estabilidade do processo e melhorar a capacidade do mesmo reduzindo a variabilidade existente (Montgomery, 2013b).

É referido na literatura enquanto um dos melhores desenvolvimentos tecnológicos do século XX devido aos princípios que sustentam esta ferramenta, pelo facto de se tratar de uma ferramenta simples, mas com um campo de aplicação amplo, traduzindo-se, contudo, em resultados bastante significativos. Associados a esta ferramenta encontram-se 7 sub-ferramentas essenciais ligadas aos aspetos técnicos de aplicação do SPC:

- Histograma
- Fluxograma
- Folhas de registo e verificação
- Diagrama de Pareto
- Diagrama causa-efeito

- Gráfico de Dispersão
- Cartas de Controle

De todas estas ferramentas, Montgomery (2013b) sugere que provavelmente as cartas de controle são as tecnicamente mais sofisticadas.

As cartas de controle, ou cartas de controle de Shewhart representam uma das técnicas primárias do controle estatístico de processos e permitem controlar e avaliar um dado processo ao longo do tempo, através dos dados referentes a uma determinada característica da qualidade.

Requeijo (2003) ressalta a ideia de que uma determinada característica da qualidade que se encontre presente num processo não apresenta sempre o mesmo valor devido à presença incontornável das chamadas fontes de variação. Requeijo (2003) refere ainda que as principais fontes de variação que afetam os valores das características da qualidade podem ser agrupadas em seis categorias distintas:

- Equipamentos
- Matérias-primas
- Operadores
- Condições ambientais
- Métodos
- Metrologia

Requeijo (2003) refere por sua vez que as causas das variações podem ser categorizadas em duas classes distintas, as aleatórias vulgarmente conhecidas por causas comuns e as não aleatórias que por sua vez são designadas de causas assinaláveis (Requeijo cita Shewhart, 1931) ou especiais (Requeijo cita Deming, 1986).

Reduzir as causas comuns de variação exige por norma tomadas de decisão por parte da gestão de topo numa organização pois provavelmente deverão ser empregues alterações no sistema. Por sua vez a deteção e remoção das causas especiais deverão ser realizadas pelos operadores que trabalham diretamente com o processo.

Esta dinâmica vem perfeitamente retratada na figura 2.6 adaptada a partir da figura original de Montgomery (2013), onde é representada a importância e intervenção do controle (através dos sistemas de medição neste caso) no resultado dos *outputs*, demonstrado que o processo em si não é o único responsável pelos resultados obtidos na conversão dos *inputs* em *outputs*. Através do controle poderão ser identificados problemas e a partir daqui poderão ser ponderadas e implementadas ações corretivas que irão influenciar em grande medida os resultados obtidos para os *outputs*. Note-se que esta é uma filosofia contínua, *i.e.*, após a identificação de anomalias e implementação de ações corretivas deverá continuar a ser aplicada a verificação e acompanhamento do processo, tendo sempre em vista a deteção de causas assinaláveis e identificação das suas raízes, que por sua vez levam a um aperfeiçoamento do processo.

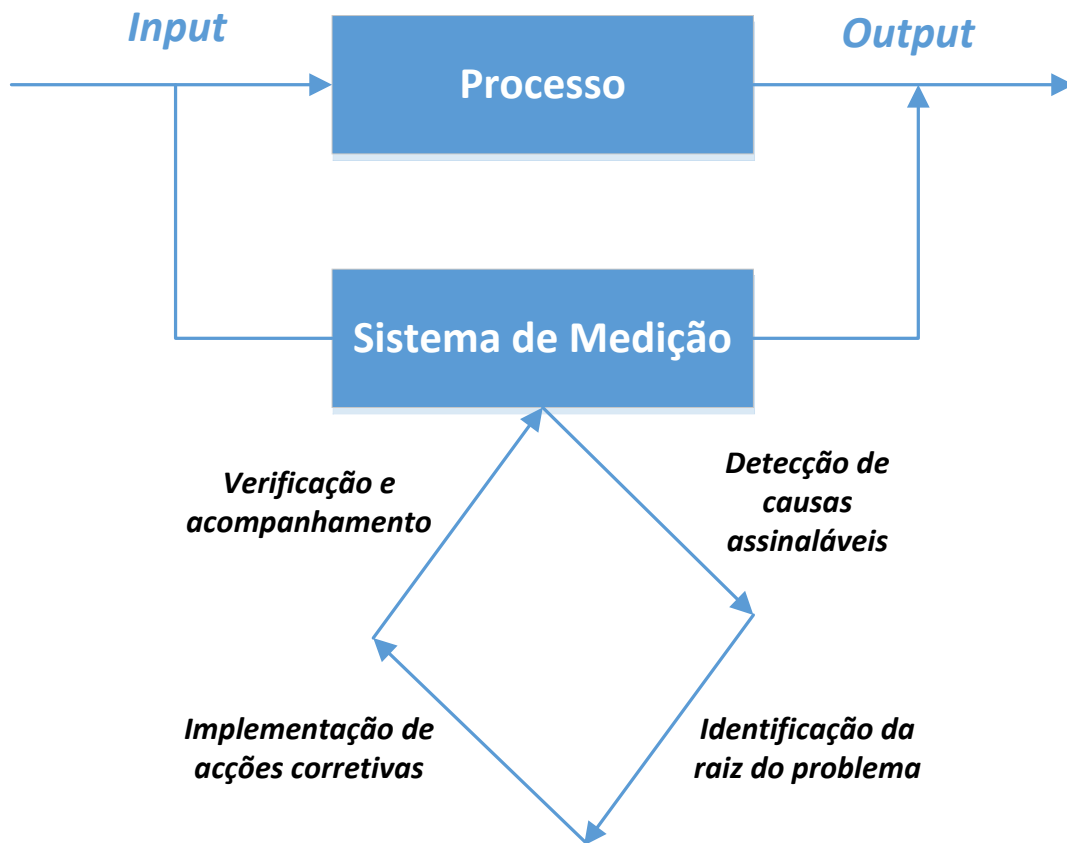


Figura 2.6 - Processo de melhoria utilizando cartas de controlo. Adaptado de: Montgomery (2013b)

2.6.2 Princípios da Abordagem Tradicional às Cartas de Controlo

Segundo Requeijo (2003), na sua essência uma carta de controlo trata-se de um gráfico que representa a evolução ao longo do tempo de uma determinada estatística w referente a uma determinada característica da qualidade. Além destes pontos representados ao longo do tempo, constituindo assim o padrão de evolução do processo, encontram-se também representados no gráfico os limites superior e inferior de controlo em adição à linha central que representa o valor médio da estatística em estudo da característica da qualidade quando esta se encontra sob controlo estatístico.

Tal como se pode verificar através da Figura 2.7 este gráfico permite analisar o processo em tempo real, e.g. se um ou diversos pontos não se encontrarem dentro do intervalo de controlo pode-se concluir que o processo se encontra fora de controlo estatístico.

Na figura 2.7 pode-se ver um modelo genérico deste gráfico para um caso em que está a ser controlada apenas uma única variável ao longo do tempo.

O gráfico é composto por duas linhas de controlo, nomeadamente o limite superior de controlo (LIC) e o limite inferior de controlo (LIC), suplementando tradicionalmente com a referência da linha central.




Figura 2.7 - Exemplo Carta de Controlo. Adaptado de: Montgomery (2013b)

A aplicação desta técnica pressupõe que os dados relativos às características da qualidade do processo em estudo sejam independentes entre si e identicamente distribuídos segundo uma distribuição Normal. É por esse motivo que uma vez mais, como foi explicado no caso do desenho de experiências, é necessário verificar os pressupostos da aleatoriedade, Normalidade e independência dos dados.

Também existem diversas situações em que os pontos apresentam padrões não aleatórios apesar de se encontrarem todos dentro do intervalo de controlo. Isto pode ser um forte indício da presença de causas especiais. Sublinha-se uma vez mais que sempre que sejam detetadas causas especiais as mesmas devem ser investigadas e devem ser aplicadas ações corretivas.

A construção das cartas de controlo assenta num procedimento distinguido em dois estágios, Fase 1 e Fase 2. As diferenças dos procedimentos a tomar têm as seguintes bases:

Tabela 2.3 - Procedimentos de construção das cartas de controlo

Processo	Fase 1	Fase 2
<i>Parâmetros</i>	Desconhecidos	Conhecidos
<i>Controlo</i>	Retrospectivo	Instantâneo (Tempo Real)
<i>Monitorização</i>	Inexistente	Existente

Na Fase 1 pretende-se em primeiro lugar verificar ou garantir a estabilidade do processo que está a ser alvo do estudo. Em segundo lugar, mas não com menor importância, pretende-se estimar os valores da média e da variância do processo. A partir destes valores torna-se então possível avaliar se as unidades produzidas satisfazem a especificação técnica utilizada, isto é, avalia-se a capacidade do processo. É através da capacidade do processo que se avalia a aptidão ou inaptidão do processo para produzir, regularmente, dentro dos limites de especificação (Requeijo, 2003).

Segundo Pereira e Requeijo (2012) para executar esta fase devem ser tomados alguns passos sequenciais que se encontram explanados de seguida:

1. Selecionar a característica da qualidade
2. Desenvolver um plano de controlo em que conste a dimensão da amostra, a frequência de amostragem, o equipamento de medição e o método de medição
3. Selecionar o tipo de carta em função da estatística (ou estatísticas) amostral a monitorizar.
4. Recolher m amostras de dimensão n durante um determinado período de tempo, perfazendo um total de N unidades ($N = mn$) garantindo que $N \geq 100$
5. Calcular a estatística a controlar para cada uma das amostras
6. Determinar os limites de controlo e a linha central, tendo por base as estatísticas calculadas a partir das m amostras
7. Verificar a existência de causas especiais de variação
8. Eliminar, se for caso disso, os pontos que denotam a existência de causas especiais de variação
9. Determinar os limites revistos e a linha central
10. Construir a carta de controlo revista
11. Verificar se o processo apresenta apenas causas comuns de variação

Já na Fase 2 o foco é concluir a estrutura da ferramenta tendo em conta os dados obtidos e as estatísticas calculadas a partir da Fase 1. Para tal executam-se os seguintes passos:

1. Representar no gráfico o LIC , LC e LSC calculados na Fase 1
2. Recolher a amostra i , determinar a estatística calculada ω_i e representar o respetivo valor no gráfico
3. Verificar se esse valor corresponde a uma causa especial de variação
4. Caso se detete uma situação de fora de controlo, identificar a causa e implementar as ações corretivas necessárias para corrigir o problema

2.6.3 Medidas de Desempenho das Cartas de Controlo

Montgomery (2013b) refere que ao desenhar as cartas de controlo devem ser especificadas a dimensão da amostra e a frequência de amostragem a serem utilizadas. Deve-se ter em mente

que, em geral, amostras maiores tornam a detecção de pequenas mudanças no processo mais fáceis. Quanto à frequência de observação, do ponto de vista da detecção de mudanças existentes o mais interessante é ter uma frequência de amostragem mais alta. Portanto a situação mais desejável é ter uma dimensão de amostra grande e uma frequência alta em simultâneo, mas muitas vezes esta situação torna-se, economicamente falando, não exequível. Também devido ao esforço que este tipo de recolha de amostras envolve, normalmente na indústria opta-se por recolher amostras pequenas frequentemente, em detrimento da recolha de amostras de maior dimensão em intervalos de tempo mais espaçados. Para além disso, atualmente começam a ser desenvolvidos e aplicados muitos tipos de tecnologia automática, como sensores e medidores, que permitem aumentar a frequência de amostragem, o que em associação a *softwares* de controlo estatístico de processo no local de trabalho conferem uma capacidade de controlo *on-line* em tempo real sobre o processo, o que torna toda a aplicação do SPC muito mais eficiente.

Tanto Montgomery (2013b) como Requeijo ao citar Chakraborty *et al* (2001) referem uma outra forma de avaliar as decisões relativas à dimensão e frequência de amostragem, através do *average run length* (ARL) das cartas de controlo. Montgomery (2013b) define ARL enquanto o numero médio de pontos que devem ser desenhados antes de um ponto indicar uma situação fora de controlo, *i.e.*, até um ponto não pertencer ao intervalo [LIC, LSC]. Se as observações forem não correlacionadas, em qualquer carta de controlo de Shewhart o valor de ARL será dado pela expressão:

$$ARL = \frac{1}{p} \quad (2.22)$$

p representa a probabilidade de qualquer ponto exceder os limites de controlo quando o processo se encontra sob controlo estatístico. No contexto do SPC tradicional usualmente $p = \alpha = 0.27\%$. Assim sendo, esta expressão simples pode ser utilizada para avaliar a performance da carta de controlo.

É desejável que este valor seja tanto maior quanto possível, a partir do momento em que o processo se encontre sobre controlo estatístico para minimizar o número de falsos alarmes, e que seja o menor possível quando se encontra fora de controlo estatístico para que detetar uma alteração do processo em controlo seja um ato rápido.

2.6.4 Tipos de Cartas de Controlo

No que diz respeito ao SPC e às cartas de controlo entende-se que existem duas famílias que diferem essencialmente no tipo de distribuições estatísticas que sustenta cada uma das linhagens. Mais concretamente, como Requeijo (2013b) refere, quando se tratam de características que são mensuráveis numa escala contínua (quantitativas) o mais adequado será utilizar as cartas de controlo de variáveis, ao passo que quando se tratam de variáveis discretas (características qualitativas= devem ser utilizadas as chamadas cartas de controlo de atributos.

Entende-se por cartas de controlo dos atributos aquelas cujas características não são mensuráveis numericamente, em que se usualmente se analisa se o produto é conforme ou não conforme. As cartas das variáveis pelo contrário são cartas que podem ser expostas através de uma qualquer escala numérica.

Requeijo (2013b) sublinha que no caso das se estarem a ser tratadas variáveis discretas é apenas construída uma única carta de controlo uma vez que o desvio padrão é calculado em função da média e da dimensão da amostra. Contudo, no caso de se tratar de variáveis contínuas, tendo em conta o facto da dispersão de uma determinada população não depender exclusivamente de uma medida de tendência central, deverão ser então construídas duas cartas de controlo, para controlar o parâmetro de localização e o parâmetro de dispersão respetivamente da população em causa. Pode ser vislumbrado em seguida um resumo cartas de controlo tradicionais, fazendo a distinção entre as cartas que são aplicadas a variáveis contínuas ou a atributos:

Tabela 2.4 - Procedimentos de construção das cartas de controlo

Cartas de controlo	
Variáveis	Atributos
Média (\bar{X}) e Amplitude (R)	Proporção de Unidades Não Conforme (p)
Média (\bar{X}) e Desvio Padrão (s)	Número de Unidades Não Conforme (np)
Média (\bar{X}) e Variância s^2	Número de Defeitos (c)
Observações Individuais (X) e Amplitudes Móveis (MR)	Número de Defeitos por unidade (u)

Estas cartas de controlo (variáveis) devem sempre ser usadas, desde que seja economicamente viável, em detrimento das cartas dos atributos (Pereira e Requeijo, 2012). Eis algumas das razões que corroboram este facto:

Muitos processos e produtos possuem características que são mensuráveis numa escala contínua.

Através de uma medição é possível obter muito mais informação do que através de uma avaliação binária. e.g. passa-não passa, sim-não, entre outras.

Regra geral é necessário recolher menos dados e, por necessitar de menos informação, o tempo para deteção e resolução de um determinado problema é menor.

Mesmo que todas as observações se encontrem dentro das especificações, o comportamento geral do processo poderá ser analisado.

Doravante serão apenas tratados as cartas e subtemas considerados pertinentes para providenciar o melhor entendimento da dissertação de forma simples e concisa.

2.6.5 Regras Para Deteção de Causas Especiais de Variação

Quando um processo está sobre controlo estatístico os pontos que compõem o padrão do processo numa carta de controlo deve ser perfeitamente aleatório. Se existir um ponto fora dos limites de controlo ou um comportamento não aleatório tiver lugar, de forma sistemática, este é um forte indício de que se está na presença de causas especiais de variação (Pereira e Requeijo, 2012).

Os padrões não naturais, ou não aleatórios, poderão ter tendência a flutuar em excesso, ou em demasia, em torno da linha central. No fundo irão sempre estar em falta algumas características comuns de um padrão aleatório, como por exemplo a inexistência de pontos próximos da linha central ou perto dos limites de controlo ou ainda a existência de pontos fora dos limites de controlo que indicam a existência de instabilidade no processo.

Segundo o *Western Electric SQC Handbook* (1958) existem algumas regras que poderão ser aplicadas, para filtrar estas tendências. O mais importante destes testes é que no fundo são testes para a instabilidade do processo. Ao aplica-los, vai-se dividir cada uma das duas áreas (acima ou abaixo da linha central) em três zonas equitativamente, *i.e.*, uma vez que os limites de controlo são dados por 3σ cada uma das zonas corresponderá a 1σ . Pode ser vista em baixo uma exemplificação destas zonas, com os últimos 4 pontos a quebrar a regra 3 que será também esta exposta em seguida.




Figura 2.8 - Regras para a detecção de causas especiais (adaptado da norma ISO 8258:1991). Fonte: Pereira & Requeijo (2012)

Fazendo jus ao que Pereira e Requeijo (2012) expõem, que por sua vez têm como base o que se encontra presente na norma ISO 8258:1991, correntemente substituída pela ISO 7870-2:2013, em seguida encontram-se as regras elaboradas para identificar estes padrões. Note-se que estas regras estão ligadas ao trabalho desenvolvido pelo *Western Electric SQC Handbook* (1958).

Regras para detecção das causas especiais:

Regra 1. Um qualquer ponto fora dos limites de ação (limites $\pm 3 \sigma_w$).

Regra 2. Nove pontos consecutivos na zona C ou para além da zona C do mesmo lado da linha central.

Regra 3. Seis pontos consecutivos no sentido ascendente ou descendente.

Regra 4. Catorze pontos consecutivos crescendo e decrescendo alternadamente.

Regra 5. Dois de três pontos consecutivos na zona A, ou além desta zona, do mesmo lado da linha central.

Regra 6. Quatro de cinco pontos consecutivos na zona B ou A, ou além destas zonas do mesmo lado da linha central.

Regra 7. Quinze pontos consecutivos na zona C acima e abaixo da linha central.

Regra 8. Oito pontos consecutivos de ambos os lados da linha central, sem nenhum na zona C.

É importante aplicar estas regras tendo em mente algumas notas:

- A regra 2 e a regra 3 são mais adequadas para processos que desafinam lentamente.
- As regras 5 e 6 são mais adequadas para processos que desafinam bruscamente.
- A regra 7 muitas vezes existe porque os limites de controlo foram mal calculados.

- Regra 8 ocorre tipicamente quando existe mistura de populações. *E.g.* quando se retiram amostras de dois equipamentos distintos.

O uso destas regras tem um enorme potencial quando nos encontramos na fase inicial da implementação de controlo estatístico do processo, altura essa em que se toma especial atenção à estabilização dos processos. A partir do momento em que o processo em causa se encontra estabilizado, as iniciativas de uso habitual destas regras tendo como objetivo detetar potenciais pequenas variações que possam surgir devem ser extinguidas, pois pequenas variações no processo poderão constituir apenas falsos alarmes (Montgomery, 2013b).

2.6.6 Cartas das Observações Individuais e Amplitudes Móveis

Existem alguns casos em que a amostra retirada do processo é composta por uma única observação individual. Nestes casos é adequado serem utilizadas as cartas de controlo de observações individuais (X) e amplitudes móveis (MR). Uma vez que através das observações individuais não é possível obter indicações acerca da dispersão do processo, recorre-se ao cálculo da amplitude móvel (*Moving Range*) para contornar esta questão (Pereira e Requeijo, 2012).

Tipicamente MR é dado através da amplitude móvel de dois valores consecutivos, como se encontra exemplificado através da seguinte expressão genérica:

$$MR = |X_i - X_{i-1}| \quad (2.23)$$

Os limites de controlo por sua vez serão dados pelas expressões expostas de seguida. Note-se que as constantes d_2 , D_3 e D_4 dependem do número de observações usadas para calcular cada amplitude móvel e podem ser obtidas através da tabela disposta no Anexo II – Tabelas e Fórmulas Estatísticas.

Para a carta X:

$$LSC_X = \bar{X} + 3\sigma_X = \bar{X} + \frac{3\overline{MR}}{d_2} \quad (2.24)$$

$$LSC_X = \bar{X} - 3\sigma_X = \bar{X} - \frac{3\overline{MR}}{d_2} \quad (2.25)$$

$$LC_X = \bar{X} = \frac{1}{m} \sum_{i=1}^m X_i \quad (2.26)$$

Enquanto que para a carta MR os limites são dados por:

$$LSC_{MR} = D_4 \overline{MR} \quad (2.27)$$

$$LIC_{MR} = D_3 \overline{MR} \quad (2.28)$$

$$LC_{MR} = \overline{MR} = \frac{1}{m-1} \sum_{i=1}^{m-1} MR_i \quad (2.29)$$

2.6.7 Estudo da Capacidade do Processo

O facto de um processo ser detentor de um índice de variabilidade alto, ou de a sua média se encontrar deslocada quando comparada com o valor nominal de especificação pode colocar em causa a capacidade do processo. Após as cartas de controlo se encontrarem implementadas verifica-se a estabilidade do processo analisando a capacidade do mesmo. No fundo ao estudar a capacidade do processo procura-se refletir a aptidão de produzir de acordo com as especificações exigidas, confrontando o intervalo de especificação com a variação existente no processo em causa.

O estudo desta matéria tem tomado a atenção de quem investiga ou aplica os conhecimentos desta área desde que se começou a desenvolver o controlo de qualidade. Este estudo, em tempos primórdios, era realizado através da proporção de unidades não conformes que um determinado processo desenvolvia.

Pereira e Requeijo (2012) referem que estudar a capacidade de um processo é de enorme importância para um plano geral de melhoria da qualidade, ao habilitar:

- Previsões acerca da capacidade de o processo produzir de acordo com as especificações
- Apoio para seleccionar ou modificar um processo ou uma máquina
- Seleção de fornecedores
- Redução da variação do processo

Este conceito desenvolveu-se ao longo do tempo e veio originar um conjunto de índices através dos quais é possível avaliar um processo face à especificação técnica que é utilizada (Requeijo, 2003).

Chandra (2001) refere que a capacidade do processo é simplesmente uma amplitude que contém todos os valores possíveis de uma determinada especificação para uma característica da qualidade, gerada por um processo circunscrito a um conjunto de condições. Chandra (2001) refere ainda que caso esteja a tratar-se de uma distribuição normal, nenhum intervalo finito contém 100% dos valores, posto isto, contudo, utiliza-se enquanto referência que um intervalo que contenha 99.73% dos valores é dado por:

$$\text{Capacidade do processo} = 6\sigma \quad (2.30)$$

Oakland (2003) pega nesta mesma questão elaborando que, atendendo à variabilidade inerente de um dado processo, a relação entre a variabilidade do processo e as suas tolerâncias podem ser formalizadas através do desvio padrão do processo. Para fabricar dentro das especificações, o limite superior de especificação e o limite inferior de especificação devem ser iguais ou superior à amplitude base de funcionamento do processo, *i.e.*, 6σ .

A partir deste raciocínio é possível definir três níveis distintos de precisão segundo Oakland (2003), tal como é expresso na Figura 2.9:

- Nível alto de precisão, onde a amplitude de especificação é muito superior a 6σ
- Nível médio de precisão, onde a amplitude de especificação é apenas superior a 6σ
- Nível baixo de precisão, onde a amplitude de especificação é inferior a 6σ




Figura 2.9 - Exemplo de níveis de precisão. Adaptado de: Oakland (2003)

Para averiguar se um processo está a produzir de acordo com a sua especificação técnica ou funcional é necessário recorrer a uma forma simples, quantitativa de expressar a capacidade do processo. Montgomery (2013b) expõe uma forma de fazer isso mesmo, através do rácio de capacidade do processo, neste caso para especificações bilaterais:

$$C_p = \frac{LSE - LIE}{6\sigma} \quad (2.31)$$

No caso do desvio padrão ser desconhecido, deverá ser substituído pela sua estimativa dada por:

$$\hat{\sigma} = \frac{\overline{MR}}{d_2} \quad (2.32)$$

Em geral, um valor superior a 1,33 para este índice é considerado um valor aceitável, contudo um processo poderá ter este valor de índice de capacidade do processo, ou índice de capacidade potencial, e estar a produzir produto não conforme, pois a média poderá não estar centrada de acordo com o valor nominal. Contudo o objetivo é que a capacidade do processo seja sempre tão grande quanto seja possível (Pereira e Requeijo, 2012).

Em jeito de complemento ao índice C_p deverá ser calculado o C_{pk} para apurar a questão da centralização do processo. Este segundo índice representa o nível de confiança que se tem na capacidade do processo (Oakland, 2003). C_{pk} é calculado através da seguinte expressão:

$$C_{PK} = \min ((C_{pk})_I, (C_{pk})_S) \quad (2.33)$$

O processo será capaz se $C_{pk} \geq 1.33$. Contudo estará centrado se $(C_{pk})_I$ e $(C_{pk})_S$ forem idênticos, pelas fórmulas:

$$(C_{pk})_I = \frac{\mu - LIE}{3 \sigma} \quad (2.34)$$

$$(C_{pk})_S = \frac{LSE - \mu}{3 \sigma} \quad (2.35)$$

2.7. Controlo de processos com Dados Auto Correlacionados

Como previamente referido nesta dissertação, a garantia de independência dos dados utilizados aquando da implementação de cartas de controlo demonstra ser um pressuposto vital na aplicação desta técnica. Contudo, nem sempre é possível garantir este facto e é nesse sentido que foram pensadas duas vertentes distintas que visam contrapor ou anular este efeito.

Em primeiro lugar, existe uma vertente defendida por Vasiloupou e Stamboulis (1978), Wardell, Moskowitz e Plante (1992) entre outros autores, que se baseia no facto de não considerar fundamental ajustar um determinado processo a um modelo matemático, frisando que, em suma, poderão ser utilizadas simplesmente as cartas tradicionais de Shewhart, desde que se modifiquem os limites de controlo.

Outra ideologia, que foi a aplicada na corrente dissertação, sugerida por Reynolds e Lu (1997) defende a aplicação de cartas de controlo aos resíduos ou erros de previsão. Em suma, qualquer variação desta técnica, depende do cálculo dos resíduos, de forma instantânea, através da seguinte expressão:

$$e_t = X_t - \hat{X}_t \quad (2.36)$$

O processo essencialmente passa por controlar os valores dos resíduos na Fase 1 e por monitorizar os erros de previsão na Fase 2 do SPC.

A versão utilizada na presente dissertação passa pela aplicação dos resíduos e dos erros de previsão às cartas de Shewhart, como sugerido por *Wardell et al* (1992).

Assim sendo, e tendo como base esta filosofia para o processamento dos dados, no caso de se comprovar que os dados utilizados no estudo e controlo de um determinado processo se encontram auto correlacionados, é necessário gerar um modelo que se ajuste da melhor forma possível ao modelo em causa. Após este passo podem ser calculados os resíduos e averiguados os pressupostos associados aos mesmos, nomeadamente a garantia de independência dos

resíduos. Após se verificar este pressuposto pode-se partir para a Fase 1 das cartas de controlo, sendo a metodologia idêntica à que foi exposta anteriormente.

Note-se que todas as considerações feitas para a construção e análise das cartas de Shewhart são aplicáveis para as cartas de controlo de resíduos, diferindo no método utilizado para ligar com as causas especiais de variação. Estes pontos, que constituem as causas especiais de variação, não deverão ser simplesmente eliminados, mas antes corrigidos, *i.e.*, devem ser alterados pelo valor que seria esperado para o ponto nesse mesmo instante. Depois desta alteração, é necessário ajustar o modelo e deverão ser determinados novos resíduos para reconstruir a carta de controlo dos resíduos.

Caso os resíduos sejam calculados com base em observações individuais, como é o caso desta dissertação, as cartas que deverão ser utilizadas são as dos próprios resíduos (e) em associação com a carta das amplitudes móveis (MR), utilizando-se para a construção da carta MR a seguinte expressão:

$$MR_t = |e_t - e_{t-1}| \quad (2.37)$$

E o correspondente valor médio por:

$$\overline{MR} = \frac{\sum_{i=2}^m MR_i}{m-1}, \text{ sendo } m \text{ o número de amostras} \quad (2.38)$$

A partir daqui os limites de controlo poderão ser calculados a partir das expressões dispostas na Tabela 2.6, onde se encontram dispostos os limites de controlo e central tanto para a carta de resíduos como para a carta de amplitudes móveis.

Tabela 2.5– Limites de controlo para cartas de resíduos e amplitudes móveis

Carta	Variável	LIC	LSC	LC
Resíduos	e	$-3\overline{MR}/d_2$	$3\overline{MR}/d_2$	0
Amplitudes Móveis	MR	$D_3\overline{MR}$	$D_4\overline{MR}$	\overline{MR}

A partir do momento em que o processo está sob controlo estatístico, os parâmetros do processo podem ser estimados, uma vez que os mesmos dependem do modelo ARIMA que está a ser utilizado como apresentado a partir do ponto 2.7.4.

Como Pereira e Requeijo (2012) referem, na Fase 2 do controlo estatístico de processo aplicam-se as cartas de Shewhart para os erros de previsão, como previamente referido. A forma de calcular os erros de previsão para o instante $T + \tau$ e a respetiva variância vêm expressos nas equações abaixo:

$$e_\tau(T) = X_{T+\tau} - \hat{X}_{T+\tau}(T) \quad (2.39)$$

$$Var(e_\tau(T)) = \sigma_\varepsilon^2(1 + \sum_{j=1}^{\tau-1} \psi_j^2) \quad (2.40)$$

Note-se que σ_ε^2 é estimado através de:

$$\sigma_\varepsilon^2 = \frac{SS(\hat{\phi}, \hat{\theta})}{r-m}, \text{ onde } r \text{ é o número de resíduos} \quad (2.41)$$

Note-se também que o coeficiente ψ_j é calculado consoante o modelo ARIMA escolhido. Uma vez que nesta dissertação se trata de um modelo AR(p) o cálculo será dado segundo a seguinte expressão:

$$\psi_j = \phi_1 \psi_{j-1} + \phi_2 \psi_{j-2} + \dots + \phi_p \psi_{j-p} \quad (2.42)$$

Existe ainda mais uma expressão importante que visa calcular o desvio padrão dos erros de previsão. Este desvio padrão será posteriormente utilizado para calcular os limites. Este valor é dado por:

$$\sigma_{ep} = \sqrt{Var(e_t(T))} = \sigma_{ep} \sqrt{(1 + \sum_{j=1}^{\tau-1} \psi_j^2)} \quad (2.43)$$

Tabela 2.6 - Carta de controlo dos erros de previsão e amplitudes móveis

Carta	Variável	LIC	LSC	LC
Erros de previsão	<i>e</i>	$-3\sigma_{ep}$	$3\sigma_{ep}$	0
Amplitudes Móveis	<i>MR</i>	$D_1\sigma_{ep}$	$D_2\sigma_{ep}$	$d_2\sigma_{ep}$

2.7.1 Séries Temporais

Box *et al* (2008) define uma série temporal enquanto uma sequência de observações retiradas sequencialmente ao longo do tempo. Box *et al* (2008) refere ainda que as séries temporais tipicamente contêm uma característica intrínseca, que consiste na existência de dependência entre observações adjacentes. Este é um fator de muito interesse e requer o desenvolvimento de modelos estocásticos e dinâmicos para analisar as séries de dados. Algumas aplicações destas técnicas são:

- Previsão de valores futuros numa série de dados temporais, desde um determinado momento para o passado
- Determinação de uma determinada função de transferência que permita perceber quais são os outputs de um determinado sistema consoante os seus inputs

- Determinação de modelos multivariados dinâmicos que juntam as relações entre várias variáveis ao longo do tempo

Para os modelos estacionários (subclasse dos modelos estocásticos) assume-se que o processo se mantém em equilíbrio em torno de um determinado valor (média). Para a indústria, a aplicação destes métodos de análise de séries temporais tem tido uma grande importância uma vez que para características não estacionárias poderão ser aplicados diversos modelos matemáticos, entre os quais os modelos ARIMA (*autoregressive integrated moving average*) que serão aprofundados adiante.

2.7.2 Verificação da Independência dos dados

A independência dos dados é uma das pedras basulares da aplicação de ferramentas estatísticas, como é o caso do SPC. Por esse motivo, quando se trabalha com séries temporais verificar se a própria variável tempo influencia a variável que se pretende estudar é imperativo. Quando se verifica que os dados não são independentes essencialmente está-se a confirmar que estes são auto correlacionados, o que se pode dever ao facto de estes não garantirem a sua vertente aleatória ou ainda, por exemplo, à própria forma como o processo ou sistema em estudo se desenrola. Isto pode ser problemático, pois tal como Alwan e Roberts (1988) referiram o facto de existir autocorrelação no processo, pode levar a que surjam padrões não aleatórios que complicam gravemente a distinção entre causas especiais e causas comuns de variação. Se se verificar que existe autocorrelação entre os dados através da rejeição do princípio da independência isto significa que em cada instante o valor da variável em estudo depende do seu valor num dos instantes anteriores de forma constante, ou seja, consoante um desfasamento contante.

Para solucionar este problema existem duas opções. Se a autocorrelação existir devido à existência de causas especiais de variação, poderão ser aplicadas cartas de controlo específicas que lidam com esse tipo de problema. Caso contrário, se existe invariavelmente autocorrelação dos dados naturais no processo em causa, por exemplo, ou caso a autocorrelação seja simplesmente significativa deverá ser aplicada a função de autocorrelação e a função de autocorrelação parcial, que permitirão a aplicação de cartas de controlo à *posteriori*. Estas ultimas foram as ferramentas utilizadas no âmbito desta dissertação.

2.7.3 FAC e FACP

A correlação entre duas observações afastadas no tempo é uma situação que acontece com alguma regularidade nos processos produtivos. À correlação de duas observações desfasadas de k instantes dá-se o nome de autocorrelação de desfasamento k (k lag). Esta autocorrelação é definida através do coeficiente de correlação ρ_k e o conjunto formado pelos coeficientes de

correlação ρ_k para distintos valores de k dá-se o nome de Função de Auto-Correlação (FAC) (Pereira e Requeijo, 2012).

$$\rho_k = \frac{Cov(X_t, X_{t+k})}{Var(X)} = \frac{\gamma_k}{\gamma_0} \text{ para } k = 0, 1, 2, 3, \dots \quad (2.44)$$

Devido ao facto de no início de um determinado estudo não se conhecer a FAC, esta deverá ser estimada a partir dos valores que a variável aleatória X apresenta. Pereira e Requeijo (2012) sugerem que seja estimada segundo a seguinte expressão:

$$r_k = \hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{N-k} (X_t - \bar{X})(X_{t+k} - \bar{X})}{\sum_{t=1}^N (X_t - \bar{X})^2}, \text{ para } k = 0, 1, 2, 3, \dots \quad (2.45)$$

Caso seja necessário, também se poderá fazer uma estimativa de auto-covariância $\hat{\gamma}_k$:

$$c_k = \hat{\gamma}_k = \frac{1}{N} \sum_{t=1}^{N-k} (X_t - \bar{X})(X_{t+k} - \bar{X}) \quad (2.46)$$

O valor do coeficiente de correlação estará sempre contido no intervalo $[-1, 1]$ dado que quando maior for a dependência existente entre o valor da variável num dado momento e o seu valor num momento anterior com desfasamento k , maior será o valor do coeficiente em valor absoluto.

Para verificar se os dados se encontram auto correlacionados deverá ser construído um correlograma FAC através do qual se deverá decidir, verificando se todos os valores r_k pertencem a um determinado intervalo de confiança, aferindo se de facto se encontram ou não autocorrelacionados. Segundo Pereira e Requeijo (2012). Este intervalo de confiança dependerá da dimensão da amostra e da variância de r_k .

$$-Z\alpha/2\sqrt{\hat{v}} \leq r_k \leq Z\alpha/2\sqrt{\hat{v}} \quad (2.47)$$

Este intervalo de confiança é determinado tendo em conta o valor esperado e a variância de r_k . Um bom estimador dessa mesma variância é dado por:

$$\hat{v} = Var(\hat{r}_k) \approx \frac{1}{N} \left(1 + 2 \sum_{v=1}^{k-1} r_v^2 \right) \quad (2.48)$$




Figura 2.10 - FACE, Função de Auto Correlação Estimada. Fonte: Pereira & Requeijo (2012)

Já a auto-correlação parcial, tal como Box *et al* (2008) referem permite avaliar a correlação parcial entre duas observações distintas, retirando o efeito das observações intermédias. Este coeficiente será definido através de ϕ_{kk} , tendo este conjunto o nome de Função de Auto-correlação Parcial (FACP). Através da Função de autocorrelação parcial é possível definir o modelo matemático ARIMA que melhor se ajusta aos dados do processo.

Se o modelo AR(p) for o modelo considerado, que é o caso desta dissertação, isto significa que a auto-correlação é definida recorrendo às equações de Yule-Walker, através de uma das duas expressões que se seguem:

$$\begin{bmatrix} 1 & \cdots & p_{k-1} \\ \vdots & \ddots & \vdots \\ p_{k-1} & \cdots & 1 \end{bmatrix} \begin{bmatrix} \phi_{k1} \\ \vdots \\ \phi_{kk} \end{bmatrix} = \begin{bmatrix} p_1 \\ p_2 \\ p_3 \end{bmatrix} \quad (2.49)$$

$$\phi_k = P_K^{-1} \rho_K \quad (2.50)$$

Contudo, os coeficientes ϕ_{kk} não são conhecidos, mas, segundo Quenquille (1949) poderão ser estimados através de:

$$\hat{\phi}_{kk} = \frac{\hat{\rho}_k - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \cdot \hat{\rho}_{k-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{k-1,j} \cdot \hat{\rho}_{k-j}} \quad (2.51)$$

Dá-se o nome de FACPE (Função de Auto-correlação Parcial Estimada) ao conjunto formado pelos coeficientes de auto-correlação parcial estimados.

2.7.4 Modelos Integrados Mistos Auto-Regressivos de Médias Móveis

Tal como já foi referido acima, por vezes os dados relativos a uma determinada característica da qualidade são auto-correlacionados. Muitas vezes isto acontece devido à tendência para a automatização na aquisição de dados acerca de um determinado processo ou então devido à dinâmica dos próprios sistemas. Caso esse facto se verifique torna-se imperativo desenvolver um modelo matemático que se ajuste às necessidades do estudo. No caso desta dissertação foram utilizados os métodos de Box *et al* (1994) conhecidos enquanto modelos ARIMA, que depois foram explorados por diversos autores, que também serviram de referência para esta dissertação, como Pereira e Requeijo (2012), Shumway e Stoffer (2011), Wei (2006), Requeijo (2003) entre outros. Esta técnica consiste essencialmente na modelação de um processo através de uma ferramenta de modelação de análise de sucessões cronológicas conhecida como modelos integrados mistos auto-regressivos de médias móveis, comumente abreviada para a sua sigla já referida ARIMA (p,q,d).

As características da qualidade associadas a um dado sistema tipicamente poderão ser fenómenos dinâmicos. Isto significa que uma dada variável depende da influência de outras variáveis no mesmo instante e em instantes anteriores. O facto de existir esta dinâmica obriga a que sejam aplicados modelos probabilísticos, uma vez que os modelos determinísticos

permitiram perceber qual é a relação entre as variáveis de um dado sistema, mas sem inclusão de qualquer tipo de incerteza. Já no método estocástico, coloca-se uma dada probabilidade de ocorrência a um certo acontecimento o que permite incluir a incerteza no modelo.

Através dos modelos ARIMA, é possível prever valores futuros com base no historial de dados existente. Estes modelos destacam-se por possuir três componentes distintas:

- AR(p) - Auto-regressiva de ordem p
- d - I(d) - Integrativa com grau de diferenciação d
- q - MA(q) – Componente de médias móveis de ordem q

Note-se que, contudo, as três componentes poderão, ou não, estar todas presentes simultaneamente numa determinada sucessão cronológica.

Um modelo ARIMA é definido, genericamente, pela seguinte equação:

$$\phi_p(B) \cdot \nabla^d \cdot X_t = \theta_q(B) \cdot \varepsilon_t \quad (2.52)$$

Note-se que B representa o operador de desfasamento, ∇ o operador de diferenças, $\phi_p(B)$ o polinómio auto-regressivo de ordem p, $\theta_q(B)$ o polinómio de médias móveis de ordem q, X_t a observação num dado instante t e por fim ε_t o “ruído branco” num dado $t (\varepsilon \sim N(0, \sigma_\varepsilon^2))$. O operador de diferenças pode ser calculado através das expressões que se seguem:

$$B^m \cdot X_t = X_{t-m} \quad (2.53)$$

$$\nabla = (1 - B) = \frac{X_{t-1}}{X_t} \quad (2.54)$$

$$\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \quad (2.55)$$

$$\theta_p(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_p B^p) \quad (2.56)$$

Onde por sua vez m representa o número de tempos de atraso que o B impõe à observação X_t

É importante reter que caso um dado processo seja estacionário, para ajustar a série temporal é necessário aplicar um modelo ARMA(p,q). Se não for esse o caso, é necessário executar uma diferenciação da série as vezes que forem necessárias até que este seja estacionário e se possa ajustar o modelo ARIMA (p,d,q) a um ARMA (p,q), sendo esta diferenciação feita através do operador de diferenças. Note-se que os processos estacionários podem ser divididos em:

- Processos AR(p)
- Processos MA(q)
- Processos ARMA(p,q).

No caso desta dissertação foi considerado o processo AR(p) e por esse motivo será este o mais aprofundado.

2.7.5 Processo AR(p)

Neste modelo o valor da característica no instante t é apresentado enquanto uma combinação linear dos valores nos instantes anteriores o que significa que a média ponderada das p primeiras observações anteriores da variável constituem a observação X_t .

Este modelo, a média e a variância podem ser descritas respetivamente pelas equações seguintes:

$$X_t = \xi + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t \quad (2.57)$$

$$E(X_t) = \mu = \frac{\xi}{1 - \sum_{j=1}^p \phi_j} \quad (2.58)$$

$$Var(X_t) = \gamma_0 = \frac{\sigma_\varepsilon^2}{1 - \sum_{j=1}^p \phi_j \cdot \phi_j} \quad (2.59)$$

Onde ξ representa a média do processo, X_{t-p} o valor da variável num dado instante $t-p$, ϕ_{pj} a componente autorregressiva, σ_ε^2 variância do erro ε e ε_t o resíduo/erro de previsão no instante t , com ε_t a seguir uma distribuição Normal $(0, \sigma_\varepsilon^2)$. Note-se que num dado processo autorregressivo o correlograma da FAC deverá apresentar um decréscimo exponencial a partir de uma certa ordem de desfasamento, sem nunca ficar nulo. Já o da FACP deverá apresentar picos significativos através dos desfasamentos p , que servem para indicar a ordem do modelo.

2.7.6 Processo MA(q)

Neste modelo, de médias móveis, o valor de X_t deixa de ser obtido através dos valores do processo nos instantes passados para passar a ser obtido a partir da combinação linear de um número finito (nomeadamente, q) de componentes aleatórias.

Neste processo o correlograma da FAC irá apresentar será diferente do anterior uma vez que será caracterizado por picos significativos nesta instância. O correlograma da FACP é analisado da mesma forma que para o modelo AR (p).

2.7.7 Processo ARMA (p, q)

Este processo não passa de uma combinação dos dois modelos anteriores, o que resulta num modelo auto-regressivo de médias móveis que em determinadas situações permite melhorar o nível de ajustamento do modelo matemático criado às series temporais de dados.

Neste caso os correlograma (FAC e FACP) apresentaram um decréscimo exponencial a partir de uma certa ordem, sem nunca atingir o valor zero. Contudo este decréscimo poderá ser positivo, negativo ou misto.

2.7.8 Caracterização dos Correlogramas

Para caracterizar os correlogramas é necessário ter três ideias em mente:

- Para identificar o modelo ARMA (p,q,) é necessário realizar a comparação das funções estimadas com as teóricas, *i.e.*, FACE com a FAC e da FACPE com a FACP
- Para processos estacionários, a FAC e FACP de qualquer um dos processos possui determinadas características que caracterizam a sucessão cronológica apresentada
- Certos autores sugerem que para proceder de forma satisfatória à identificação do modelo os autores mais conservadores sugerem que seja recolhido um mínimo de 100 observações para fazer o estudo ao passo que os menos conservadores consideram 50 observações um valor razoável

Pegando nestes pontos é possível executar a caracterização que vem exposta em seguida:

Tabela 2.7 - Critério de caracterização dos modelos ARIMA

<i>Processo de decisão</i>	<i>FAC</i>	<i>FACP</i>
AR(p)	Sem nunca atingir o valor 0 apesar de tender para o mesmo, apresenta um decréscimo exponencial a partir de determinada ordem.	Apresentará picos significativos após os quais cai abaixo dos limites após um certo lag p e será possível indicar um determinado a ordem do modelo.
MA(q)	Apresentará picos significativos após os quais cai abaixo dos limites e será possível indicar a ordem do modelo.	Sem nunca atingir o valor 0 apesar de tender para o mesmo, apresenta um decréscimo exponencial a partir de determinada ordem.
ARMA (p;q)	Apresenta um decréscimo exponencial a partir de um certo lag (q-p)m tendendo para zero sem nunca o atingir.	Apresenta um decréscimo exponencial a partir de um certo lag (q-p)m tendendo para zero sem nunca o atingir.

Para elaborar um modelo ARIMA, segundo Pereira e Requeijo (2012), o processo iterativo poderá ser executado através dos passos sequenciais dispostos na Figura 2.11, que se encontra na página seguinte devido à larga dimensão da Figura 2.11.

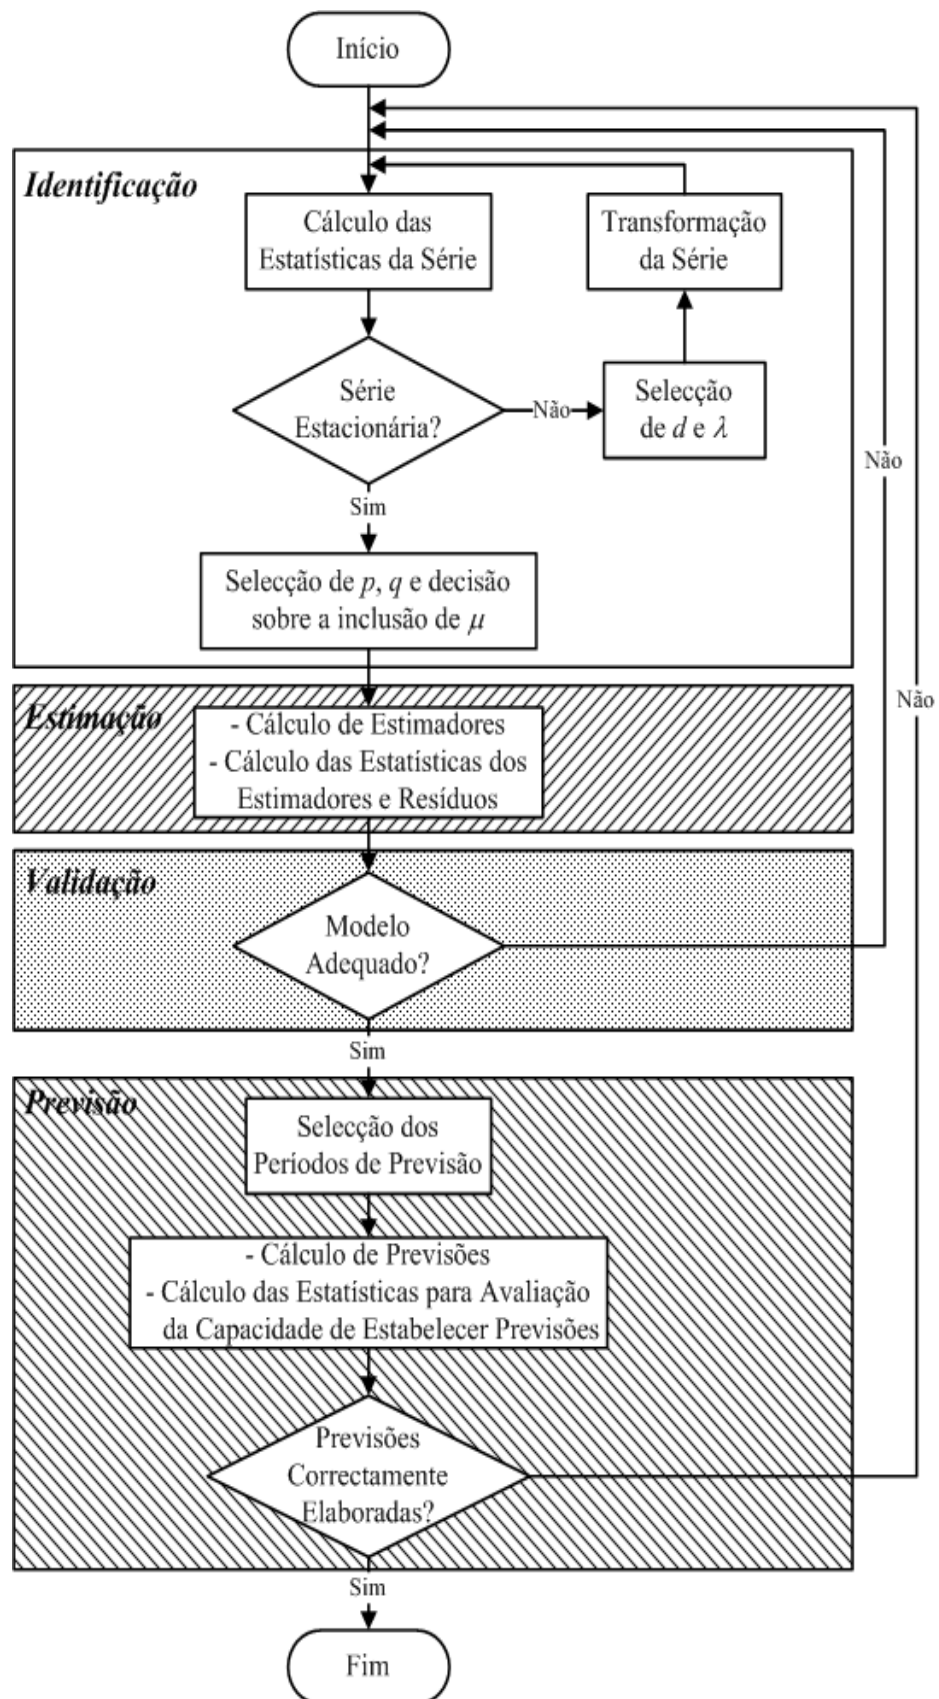


Figura 2.11 - Fases na elaboração de um modelo ARIMA. Fonte: Pereira & Requeijo (2012)

2.8. Controlo Estatístico Multivariado do Processo

Através do controlo estatístico multivariado do processo torna-se possível o controlo simultâneo de diversas características da qualidade, recorrendo a um determinado conjunto de técnicas estatísticas e de modelação matemática. Como foi dito previamente, o controlo estatístico de processo do ponto de vista prático poderá tornar-se numa ferramenta insustentável do ponto de vista da aplicação prática pelo potencial de se tornar demasiado morosa, consumir bastante tempo para ser bem aplicada e/ou analisada ou ainda devido à carga documental que poderá gerar, especialmente se se controlarem diversas características individualmente em simultâneo. Um fator agravante relativamente a esta situação prende-se com a potenciais autocorrelações entre as características da qualidade presentes num determinado processo. Se tal facto se comprovar e se as características forem controladas individualmente o controlador de processo poderá estar a ser induzido em erro.

Uma distinção relevante entre o controlo univariado e o controlo multivariado prende-se com o facto de no caso do controlo univariado, quando são utilizadas as cartas clássicas (de Shewhart), o risco de aparecerem valores fora dos limites quando o processo se encontra sob controlo estatístico é de 0.27%. Já no caso do estudo multivariado, se estiverem a ser controladas duas variáveis por exemplo, o mesmo risco tem uma probabilidade de 0.00729% (0.0027^2). Caso o número de variáveis seja superior, este diferencial torna-se cada vez mais notório.

O risco do tipo I (α), que está explicado mais detalhadamente no capítulo relativo a outros conceitos estatísticos, é dado pela seguinte expressão:

$$\alpha = 1 - \prod_{i=1}^p (1 - \alpha_i), \text{ onde } p \text{ é o número de características da qualidade} \quad (2.60)$$

Já a probabilidade de todos os pontos estarem dentro do intervalo de controlo é dado pela expressão:

$$P = \prod_{i=1}^p (1 - \alpha_i) \quad (2.61)$$

O estudo multivariado, à semelhança do que se sucede no estudo univariado, também se separa em duas fases (Fase 1 e Fase 2). Na Fase 1 recolhem-se os dados (no mínimo 100 observações por característica segundo Pereira e Requeijo, (2012)) e faz-se o estudo retrospectivo do processo, determinado os limites de controlo e estimando os parâmetros caso se comprove, tal como anteriormente, que o processo está sob controlo estatístico. Já na Fase 2 os limites de controlo são implementados com base nos parâmetros que foram calculados na Fase 1 e entra-se na fase de monitorização do processo.

Montgomery (2013b) refere que os primeiros passos nesta matéria foram dados por Hotelling em 1947, tendo sido feitos os primeiros desenvolvimentos no período da 2ª guerra mundial. Contudo, hoje em dia esta matéria é alvo de atenções por parte de diversos investigadores. Diversos autores conferem também responsabilidades aos trabalhos de Lowry, Crosier e Hawkins e Alt.

Quando um dado processo detém dados auto correlacionados, as cartas de controlo devem ser elaboradas a partir dos resíduos das variáveis em causa, com é o caso da presente dissertação. Na Fase 2 as cartas de controlo elaboradas são as dos erros de previsão.

No âmbito desta dissertação foram aplicadas as cartas T^2 de Hotelling para observações individuais.

2.8.1 Cartas de controlo Multivariadas – Observações Individuais

Assumindo que existem p características da qualidade e que são realizadas m observações individuais, ou seja, que se procede à recolha de X_{jk} ($j=1,2,\dots,p; k=1,2,\dots,m$) amostras, e sabendo que as p características da qualidade seguem uma distribuição Normal multivariada com vetor média $\mu^T = (\mu_1, \mu_2, \dots, \mu_p)$ poderá ser iniciado o estudo multivariado. A partir das observações individuais poderão ser calculadas as estatísticas necessárias, *i.e.*, as médias, as variâncias as covariâncias amostrais que são dadas por:

$$\bar{X}_j = \frac{1}{m} \sum_{k=1}^m X_{jk} \quad (2.62)$$

$$S_{jj} = \frac{1}{m-1} \sum_{k=1}^m (X_{jk} - \bar{X}_j)^2 \quad (2.63)$$

$$S_{jh} = \frac{1}{m-1} \sum_{k=1}^m (X_{jk} - \bar{X}_j)(X_{hk} - \bar{X}_h) \quad (2.64)$$

Nas equações acima expostas, X_{jk} representa a observação k da característica da qualidade j . O raciocínio é análogo para a característica h . As médias obtidas (\bar{X}_j) irão constituir o vetor média (\bar{X}) e os valores das variâncias (2.92) e das covariâncias (2.93) irão formar a matriz das covariâncias S . Já as observações p recolhidas na amostra k irão compor o vetor X_k .

$$\bar{X} = (\bar{X}_1, \bar{X}_2, \dots, \bar{X}_p)^T \quad (2.65)$$

$$S = \begin{bmatrix} S_{11} & \cdots & S_{1p} \\ \vdots & \ddots & \vdots \\ S_{p1} & \cdots & S_{pp} \end{bmatrix} \quad (2.66)$$

$$X_k = (X_{1k}, X_{2k}, \dots, X_{pk})^T \quad (2.67)$$

Com base nestas expressões torna-se possível determinar a estatística necessária para se passar à Fase 1 de construção da carta T^2 . Essa estatística e respetivos limites de controlo são dados por:

$$(T^2)_k = (X_k - \bar{X})^T S^{-1} (X_k - \bar{X}) \quad (2.68)$$

$$LSC_{T^2} = \frac{(m-1)^2}{m} \beta_{\alpha; p/2, (m-p-1)/2} \quad (2.69)$$

$$LIC_{T^2} = 0 \quad (2.70)$$

Note-se a variável $\beta_{\alpha;p/2,(m-p-1)/2}$ representa o percentil à direita da distribuição Beta, para uma probabilidade α e parâmetros $p/2$ e $(m-p-1)/2$. Nem sempre é possível efetuar os cálculos da distribuição Beta. Nestes casos, segundo Pereira e Requeijo (2012) pode-se determinar através da distribuição de Fisher com a seguinte expressão:

$$\beta_{\alpha;p/2,(m-p-1)/2} = \frac{\frac{p}{m-p-1} F_{\alpha;p,(m-p-1)}}{1 + \frac{p}{m-p-1} F_{\alpha;p,(m-p-1)}} \quad (2.71)$$

Assim sendo, verifica-se que se está perante uma causa especial nos casos em que $T^2 > LSC_{T^2}$. Nestes casos, são retiradas as observações individuais que contribuem para a existência dessa mesma causa especial e reinicia-se o processo a partir do momento de cálculo das médias amostrais.

Estando o processo sob controlo estatístico pode-se dar início à Fase 2 das cartas de controlo. Neste ponto, deverá ser implementada a carta de controlo χ^2 após o processo se encontrar sob controlo estatístico por um longo período de tempo. O cálculo da estatística χ^2 e dos respetivos limites de controlo são executados através de:

$$(\chi^2)_k = (X_k - \mu)^T \Sigma^{-1} (X_k - \mu) \quad (2.72)$$

$$LIC_{\chi^2} = 0 \quad (2.73)$$

$$LSC_{\chi^2} = \frac{p(m+1)(m-1)}{m(m-p)} F_{\alpha;p,m-p} \quad (2.74)$$

Na Fase 2 se, tal como anteriormente, $T^2 > LSC_{T^2}$ e / ou $\chi^2 > LSC_{\chi^2}$, significa que se está perante uma causa especial de variação e as devem ser apuradas quais são as variáveis responsáveis pela anomalia e devem ser implementadas medidas corretivas.

2.8.2 Interpretação da carta de controlo (T^2)

Ao analisar as cartas multivariadas é fulcral perceber quais são as variáveis que contribuíram para uma determinada causa especial num dado momento, *i.e.*, que levaram a que um ponto se encontrasse fora dos limites de controlo. O facto de uma determinada causa especial ter surgido pode dever-se a uma ou mais variáveis, ou então ainda se poderá dever à potencial existência de correlação entre variáveis. De qualquer dos modos sublinha-se uma vez mais que só através da identificação das variáveis responsáveis é que poderão ser implementadas medidas corretivas. Para realizar esta identificação, existem métodos distintos que foram desenvolvidos ao longo do tempo. *E.g.* Montgomery (2013b) refere a aplicação do método da estatística d e Jackson (1985) refere a decomposição em componentes principais. O método utilizado nesta dissertação foi o da estatística d , contudo pode ser verificada em seguida uma lista de alguns métodos existentes para identificar as características responsáveis pela ocorrência de pontos fora de controlo, segundo Pereira e Requeijo (2012):

- Decomposição em componentes ortogonais
- Cartas univariadas com limites de diagnóstico
- Método do ponto crítico
- Cartas multivariadas com limites baseados nas desigualdades de Bonferroni

2.8.3 Estatística d

Este método é profundamente vantajoso maioritariamente pela simplicidade de aplicação e interpretação a ele associado. Como foi dito no tópico anterior, o objetivo é determinar, através desta técnica, quais são as variáveis responsáveis pela existência de uma determinada causa especial de variação. O método aplica-se através do cálculo exposto na equação 2.75. Quando a condição exposta em 2.76 se verifica pode-se concluir que a variável i é a variável responsável pela situação fora de controlo. A partir do momento em que não sejam identificadas quaisquer características enquanto responsáveis por causas especiais de variação pode-se assumir que a causa de variação se deve à alteração da correlação entre variáveis.

$$d_i = T^2 - T_{(i)}^2, \text{ onde } i = 1, 2, \dots, p \quad (2.75)$$

$$d_i > \chi_{\alpha;1}^2 \quad (2.76)$$

Note-se que T^2 representa o valor da estatística de Hotelling calculado a partir das p variáveis e $T_{(i)}^2$ representa o valor da estatística de Hotelling com base nas p variáveis retirando a variável i . Note-se que para aplicar o controlo multivariado é necessário garantir uma vez mais os pressupostos da aleatoriedade e normalidade dos dados.

2.8.4 Capacidade Multivariada do Processo

Os índices de capacidades considerados nesta dissertação são os de Shahriari *et al* (1995). O estudo da capacidade multivariada do processo, em parte por ser mais complexa do que no caso univariado, motivou diversos autores a dedicarem-se a análise desta matéria. O método utilizado nesta dissertação, contudo, baseia-se no cálculo dos índices C_{pM} , PV e LI. O primeiro índice referido serve maioritariamente para comparar a região de especificação do processo, dada por uma área no caso desta dissertação pois $p=2$, com a região do próprio processo, que é dado por uma elipse no caso desta dissertação (como se pode verificar na Figura 2.12), uma vez mais porque $p=2$, equiparando-se assim ao índice de capacidade univariada C_p . Na expressão de cálculo deste índice multivariado, o denominador representa a região modificada do processo, *i.e.*, é referente a um menor p -retângulo que contém o elipsoide. O índice PV por sua vez serve para comparar a localização do vetor média do processo com a localização do vetor T dos valores nominais de especificação (Pereira e Requeijo, 2012). Por fim o índice LI servirá maioritariamente para localizar as regiões definidas pela especificação e pelo processo em si ao verificar se o processo se desenrola dentro da especificação do mesmo (Pereira e Requeijo, 2012).

Assim sendo, o índice C_{pM} é dado por:

$$C_{pM} = \left(\frac{\text{Volume da região referente à especificação}}{\text{Volume modificado referente ao processo}} \right)^{1/p} = \left(\frac{\prod_{i=1}^p (LSE_i - LIE_i)}{\prod_{i=1}^p (LSP_i - LIP_i)} \right)^{1/p} \quad (2.77)$$

Onde:

$$LSP_i = \mu_i + \sqrt{\frac{\chi_{\alpha;p}^2 \det(\Sigma_i^{-1})}{\det(\Sigma_i^{-1})}}; i = 1, 2, \dots, p \quad (2.78)$$

$$LIP_i = \mu_i - \sqrt{\frac{\chi_{\alpha;p}^2 \det(\Sigma_i^{-1})}{\det(\Sigma_i^{-1})}}; i = 1, 2, \dots, p \quad (2.79)$$

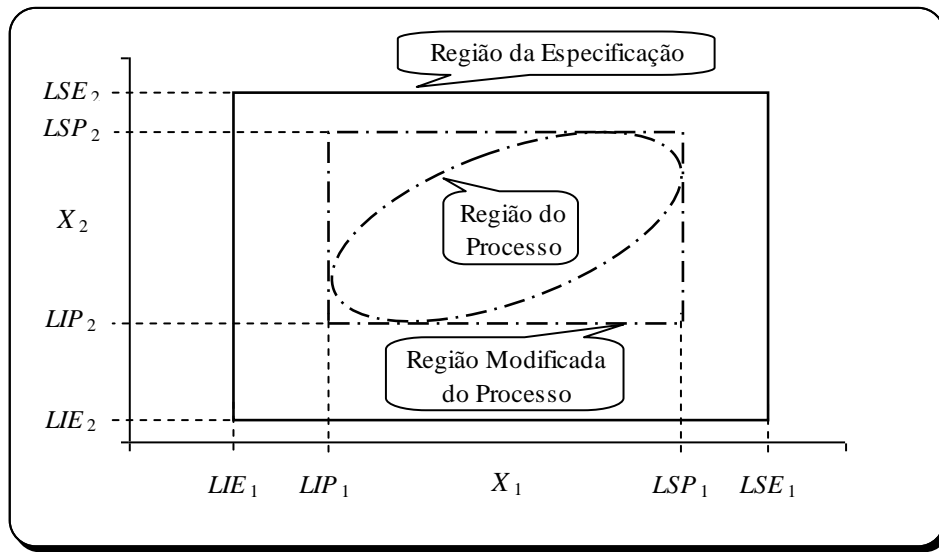


Figura 2.12 - Região modificada do processo p=2. Fonte: Pereira & Requeijo (2012)

Dado que:

Σ – matriz de covariâncias

Σ_i – matriz das covariâncias desprezando a coluna i e a linha i da matriz em causa

$\det(\Sigma_i^{-1})$ – determinante da matriz inversa de Σ_i

$\chi_{\alpha;p}^2$ – percentil à direita, para a probabilidade α , da distribuição χ^2 com p graus de liberdade

O vetor PV, tal como referido acima, serve para comparar a localização da especificação técnica com a do processo. A expressão que define este índice parte do princípio que a especificação técnica é o objetivo para o centro do processo (Pereira e Requeijo, 2012).

A expressão é dada por:

$$PV = P(T^2 > \frac{p(N-1)}{N-p} F_{\alpha, N-p}) \quad (2.80)$$

O vector dos valores nominais de especificação, utilizado para calcular T^2 é dado por:

$$T = (T_1, T_2, \dots, T_p)^p \quad (2.81)$$

E a estatística T^2 é dada por:

$$T^2 = n(\hat{\mu} - T)^T S^{-1}(\hat{\mu} - T) = n(\bar{\bar{X}} - T)^T S^{-1}(\bar{\bar{X}} - T) \quad (2.82)$$

Por fim, o índice LI serve para analisar as regiões definidas pela especificação e pelo processo, verificando se a região definida pelo processo está definida pela especificação. Faz isto comparando os intervalos da especificação ($[LIE, LSE]_i$) e do processo ($[LIP, LSP]_i$) para todas as características. Se todas as características estiverem contidas no intervalo de especificação, LI toma o valor 1. A forma de verificar este facto é dada pela seguinte expressão:

$$LI = \begin{cases} 1 & \text{se a região modificada do processo estiver contida na região de especificação} \\ 0 & \text{se a primeira condição não se verificar, ou surgir outra situação} \end{cases} \quad (2.83)$$

Considera-se o processo capaz quando se verifica que $C_{pM} \geq 1,33$, $PV = 1$ e $LI = 1$

2.9. Outros Conceitos Estatísticos

Neste ponto serão abordados alguns conceitos estatístico, soltos, contudo relevantes no âmbito desta dissertação que não foram aprofundados nos tópicos até ao momento. Note-se que existe uma panóplia de testes existentes, mas apenas serão abordados os testes e conceitos utilizados no contexto desta dissertação

2.9.1 Teste de Hipóteses

Frequentemente, o objetivo de uma dada investigação passa não por estimar um parâmetro, mas sim por decidir qual das duas afirmações contraditórias acerca de um dado parâmetro é correta. Os métodos que permitem realizar este tipo de inferência estatística são comumente denominados de testes de hipóteses (Devore, 2016). No fundo, através destes testes é possível tirar conclusões do tipo sim ou não sobre os parâmetros de uma ou mais populações, a partir de uma ou mais amostras dessas populações (Pereira e Requeijo, 2012). Porém, é importante entender que para além dos testes de hipóteses, existe outro tipo de teste estatístico, conhecido como teste de significância. A diferença reside no facto do teste de significância procurar quantificar a diferença entre duas hipóteses, ao passo que o teste de hipóteses pretende apenas clarificar se existe uma diferença, ou não, entre duas hipóteses (Hünniger, 2012). Tal como refere Crawley (2015), o contraste é a essência do teste de hipóteses.

Mendenhall *et al* (2013) referem que um teste de hipóteses é constituído por cinco partes distintas:

- Hipótese Nula (H_0)
- Hipótese Alternativa (H_1)
- A estatística de teste e o seu *p-value*
- A região de rejeição
- A conclusão

É importante denotar que a combinação destes 5 componentes definem um determinado teste de hipóteses. Por norma, a hipótese nula é a hipótese considerada verdadeira ao longo do teste e contém sempre uma igualdade, ao passo que a hipótese alternativa é a hipótese que se opõe à hipótese nula e é constituída por uma desigualdade de algum tipo.

E.g.

- $H_0: \mu = 19$ (2.84)

- $H_1: \mu < 19$ ou $\mu \neq 19$ ou $\mu > 19$ (2.85)

Quem investiga, utiliza os dados de amostragem para perceber qual das hipóteses é apoiada pelos dados e chega a uma de duas conclusões:

- Rejeita a hipótese nula e conclui que a hipótese alternativa é a correta
- Não rejeita a hipótese nula enquanto verdadeira

Existe uma diferença na forma como a hipótese alternativa é colocada. Se não existir uma diferença direcional (\neq) significa que estamos perante um teste de duas caudas (bilateral). Se, no entanto, existir diferença direcional ($<$; $>$) estamos perante um teste de hipóteses de uma cauda (unilateral).

A decisão de aceitar ou rejeitar a hipótese nula é baseada na informação contida na amostra retirada da população em estudo. Esta informação verifica-se duas formas:

- Estatística de teste: Número único calculado a partir da amostra
- *p-value*: a probabilidade calculada usando a estatística de teste

Estas duas medições, quer seja apenas uma delas ou as duas em conjunto, são utilizadas para as tomadas de decisão por parte de quem executa a investigação, quanto à rejeição ou não rejeição da hipótese nula.

Para decidir se se rejeita ou não a hipótese nula, é necessário entender primeiro que o conjunto de dados que constitui a estatística de teste se divide em dois grupos. O primeiro consiste nos valores que apoiam a hipótese alternativa, *i.e.* que levam à rejeição da hipótese nula, que por sua vez constitui a região de rejeição. O outro conjunto (hipótese nula) constitui a região de não rejeição. Se a estatística de teste cair na região de rejeição significa que a hipótese nula é

rejeitada. Pelo contrário, se a estatística de teste cair na região de não rejeição a hipótese nula não é rejeitada.

Por fim, para calcular os valores críticos que separam a região de não rejeição da região de rejeição está ligado ao nível de certeza estatística que se pretende obter antes de rejeitar a hipótese nula. Isto depende por sua vez do nível de confiança que quem conduz a investigação pretende para as conclusões que se irão obter e o nível de significância (α), que está ligado ao risco que se aceita correr de obter uma decisão incorreta.

O nível de significância representa o nível tolerável máximo de risco de rejeitar incorretamente a hipótese nula que se está disposto a correr. Com este nível definido, a região de rejeição pode ser definida para permitir ao investigador rejeitar a hipótese nula com um determinado grau de confiança na decisão.

Este valor α está intimamente ligado ao conceito de erro de Tipo I. Este caracteriza-se enquanto o erro de rejeitar a hipótese nula quando esta é verdadeira, em oposição ao erro de tipo II que se caracteriza enquanto o erro de não rejeitar a hipótese nula quando esta é falsa.

$$\alpha = P \{ \text{Erro Tipo I} \} = P \{ \text{Rejeitar } H_0 | H_0 \text{ é verdadeira} \} \quad (2.86)$$

$$\beta = P \{ \text{Erro Tipo II} \} = P \{ \text{Não rejeitar } H_0 | H_0 \text{ é falsa} \} \quad (2.87)$$

Assim sendo, α é muitas vezes visto como o risco do consumidor, uma vez que está ligado à probabilidade de rejeitar um lote bom, ao contrário de β que simboliza a probabilidade de aceitar um lote mau e é conhecido enquanto risco do produtor.

2.9.2 Diferença de Duas Médias

Considerando duas distribuições Normalmente independentes, com médias μ_1 e μ_2 e variâncias σ_1^2 e σ_2^2 , a hipótese de a diferença entre as duas médias ser igual a um determinado Δ_0 é dada por:

$$H_0 = \mu_1 - \mu_2 = \Delta_0 \quad (2.88)$$

$$H_0 = \mu_1 - \mu_2 \neq \Delta_0 \quad (2.89)$$

Deverão ser recolhidas duas amostras, de dimensão n_1 e n_2 respetivamente, e ser calculadas as médias amostrais (\bar{X}_1 ; \bar{X}_2). Através destes valores poderá ser calculada a estatística de teste. Note-se que a hipótese nula será rejeitada quando $|Z_0| > Z_{\alpha/2}$.

$$Z_0 = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \quad (2.90)$$

Se as duas populações tiverem médias e variâncias desconhecidas, será necessário averiguar se as variâncias são (ou não) diferentes.

Se as variâncias não forem significativamente diferentes, calcula-se a variância combinada S_p^2 :

$$S_p^2 = \frac{(n_1-1)(S_1^2) + (n_2-1)S_2^2}{n_1+n_2-2} \quad (2.91)$$

Sendo a estatística de teste neste caso dada por:

$$t_0 = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{S_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \quad (2.92)$$

A hipótese nula neste caso é rejeitada quando se verifica $|t_0| = t_{\alpha/2; (n_1+n_2-2)}$.

Caso as variâncias demonstrem ser significativamente diferentes vem:

$$t_0 = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{S_p \sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \quad (2.93)$$

E a hipótese nula é rejeitada quando $|t_0| \geq t_{\alpha/2; v}$, sendo v o número de graus de liberdade, dado por:

$$v = \frac{(S_1^2/n_1 + S_2^2/n_2)^2}{\frac{(S_1^2/n_1)^2}{n_1-1} + \frac{(S_2^2/n_2)^2}{n_2-1}} \quad (2.94)$$

3. Descrição da Organização

3.1. Unidade Industrial EQUIPAR - Amorim & Irmãos, S.A

O Grupo Amorim é uma multinacional portuguesa, com uma origem que remonta a 1870. É considerada uma organização de referência é reconhecida mundialmente enquanto líder de mercado no sector da cortiça, sendo também a mais internacional das multinacionais portuguesas, com 83 empresas e 30 unidades industriais dispostas pelo globo. O grupo com sensivelmente 3500 colaboradores, traduz-se num volume de negócios anual de cerca de 605 M €, fundamentado com a venda anual de 4 biliões de rolhas e o equivalente a 1900 campos de futebol (8 milhões m²) em revestimentos entre outros produtos distribuídos. Tem como missão “acrescentar valor à cortiça, de forma competitiva, diferenciada e inovadora, em perfeita harmonia com a Natureza” (AMORIM, 2016). É nesse sentido que se encontra, de momento, em 5 ramos de negócio distintos diretamente relacionados com a distribuição de produtos de cortiça: Matérias-Primas, Rolhas, Revestimentos, Aglomerados Compósitos e, por fim, Isolamentos. Ao inserir-se nestas unidades de negócio o Grupo Amorim intervém em mercados bastantes distintos, aplicando o seu produto em áreas completamente heterogéneas (e.g. Indústria Vinícola e Espirituosos, Construção e Infraestruturas, Indústria Aeroespacial, Desporto).

As unidades de negócio, que ao longo deste texto serão referenciadas através sua sigla “UN” são articuladas pela Comissão Executiva da Corticeira Amorim, cuja estrutura de se encontra no diagrama disposto abaixo.

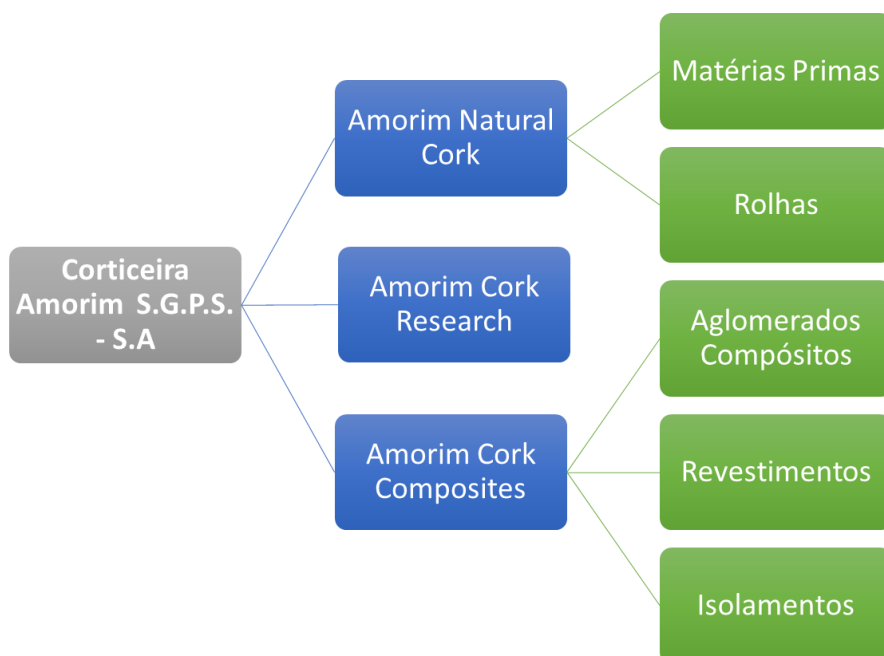


Figura 3.1 - Organograma da Corticeira Amorim

Este estudo foi executado na unidade industrial EQUIPAR - Rolha Natural, S.A, situada em Coruche na Zona Industrial do Monte da Barca, contando com cerca 191 colaboradores à data da dissertação. Esta unidade industrial insere-se na UN Rolhas e foca-se nas atividades de trituração para criação de granulado de cortiça, na produção e acabamento de rolhas aglomeradas e rolhas técnicas. Segundo a APCOR (2016) pode-se entender que as rolhas aglomeradas são rolhas inteiramente fabricadas a partir de granulados de cortiça provenientes de subprodutos resultantes da produção de rolhas naturais, *i.e.*, rolhas obtidas diretamente a partir de uma peça única de cortiça através de um processo de brocagem, podendo ser fabricadas através dos processos industriais de moldação ou extrusão, adicionando uma substância aglutinadora para ligar os granulados de cortiça. Passam a denominar-se rolhas técnicas aquelas que após passarem pelo processo de criação de rolhas aglomeradas ainda passam por um processo de colagem para serem adicionados discos de cortiça natural no seu topo, ou em ambos os topos.

3.2. Produtos

A organização Corticeira Amorim S.G.P.S. disponibiliza uma vasta gama de produtos para corresponder às exigências e necessidades dos seus clientes. Estes produtos são concebidos para corresponderem aos altos padrões de desempenho a que irão ser submetidos. No caso da EQUIPAR, como já foi referido, são produzidas rolhas técnicas e aglomeradas para serem aplicadas a vinhos de consumo rápido.

Estas rolhas são elaboradas a partir de granulado de cortiça, que se subdivide em diferentes tipos:

Tabela 3.1 -Caracterização de granulados, EQUIPAR S.A.

Tipo de granulado	ΦMínimo	ΦMáximo
<i>RCT</i>	3	7
<i>RA</i>	2	3
<i>RN₂</i>	1	2
<i>BD</i>	0,5	1
<i>AD₁₋₂</i>	1	2
<i>AD_{0,5-1}</i>	0,5	1
<i>ADT</i>	1	2
<i>Terras</i>	-	-

Estes tipos de granulado dão origem a diversos tipos de rolha, com um vasto conjunto de calibres disponíveis. Nomeadamente:

- Rolhas 0+1: Rolha técnica à qual se junta um disco de cortiça num dos topos
- Rolhas 0+2: Rolha técnica à qual se juntam dois discos de cortiça num dos topos
- Rolhas Advantec: Rolha técnica revestida que integra todas as medidas preventivas e corretivas de combate ao TCA. Poderá ainda tornar-se numa gama Advantec Colours no caso de ser colorida.
- Rolha Aglomerada: Rolha aglomerada simples
- Rolha Aglomerada Champanhe: Rolhas técnicas concebidas para vedar champanhe, vinhos espumantes, vinhos gaseificados e sidra, na qual é aplicado a um dos topos um, dois ou três discos de cortiça natural

Note-se que dentro destes diversos tipos de rolhas existem muitos subprodutos distintos dependendo da combinação calibre-classe-acabamento a que as rolhas são sujeitas.

3.3. Fluxo de Produção

No fluxograma que se segue, encontra-se o processo geral de fabrico das rolhas aglomeradas e técnicas seguido de uma breve explicação de alguns processos chave para um melhor entendimento dos conteúdos da presente dissertação. Note-se que apesar do que encontra representado no fluxograma que se segue, o granulado e as rolhas nem sempre seguem os percursos expostos. Face à vastidão de produtos que a EQUIPAR pode fornecer, entre diferentes tipos de granulado com diferentes tipos de tratamento e diferentes tipos de rolha, as necessidades internas e as atividades de reprocessamento fazem com que o fluxo de materiais possa ter algumas variantes face ao que se encontra exposto. Poderá existir granulado ou rolhas de cortiça que saltam certas fases ou mesmo que passam de uma secção para outra para responder aos requisitos que o mercado exige. Estas situações todas não se encontram representadas no fluxograma, pois levaria a um diagrama muito mais complexo, que seria menos perceptível e menos interessante do ponto de vista desta dissertação. Por esse motivo, optou-se por apresentar o processo geral que os materiais atravessam ao longo da EQUIPAR da Amorim e irmãos, de forma a que se fique com uma ideia geral do fluxo de produção e seja contextualizado nas matérias envolventes a esta dissertação.

No fluxograma disposto na Figura 3.2 encontram-se classificados os diferentes tipos de granulado e quais os destinos gerais que estes tendem a tomar no fluxo produtivo, assim como os principais processos produtivos presentes na EQUIPAR. Alguns destes processos dão o nome aos pavilhões onde se inserem, tais como a Trituração, Rosa ou a Embalagem por exemplo. Os principais sectores e/ou processos serão explorados após a demonstração do fluxograma.

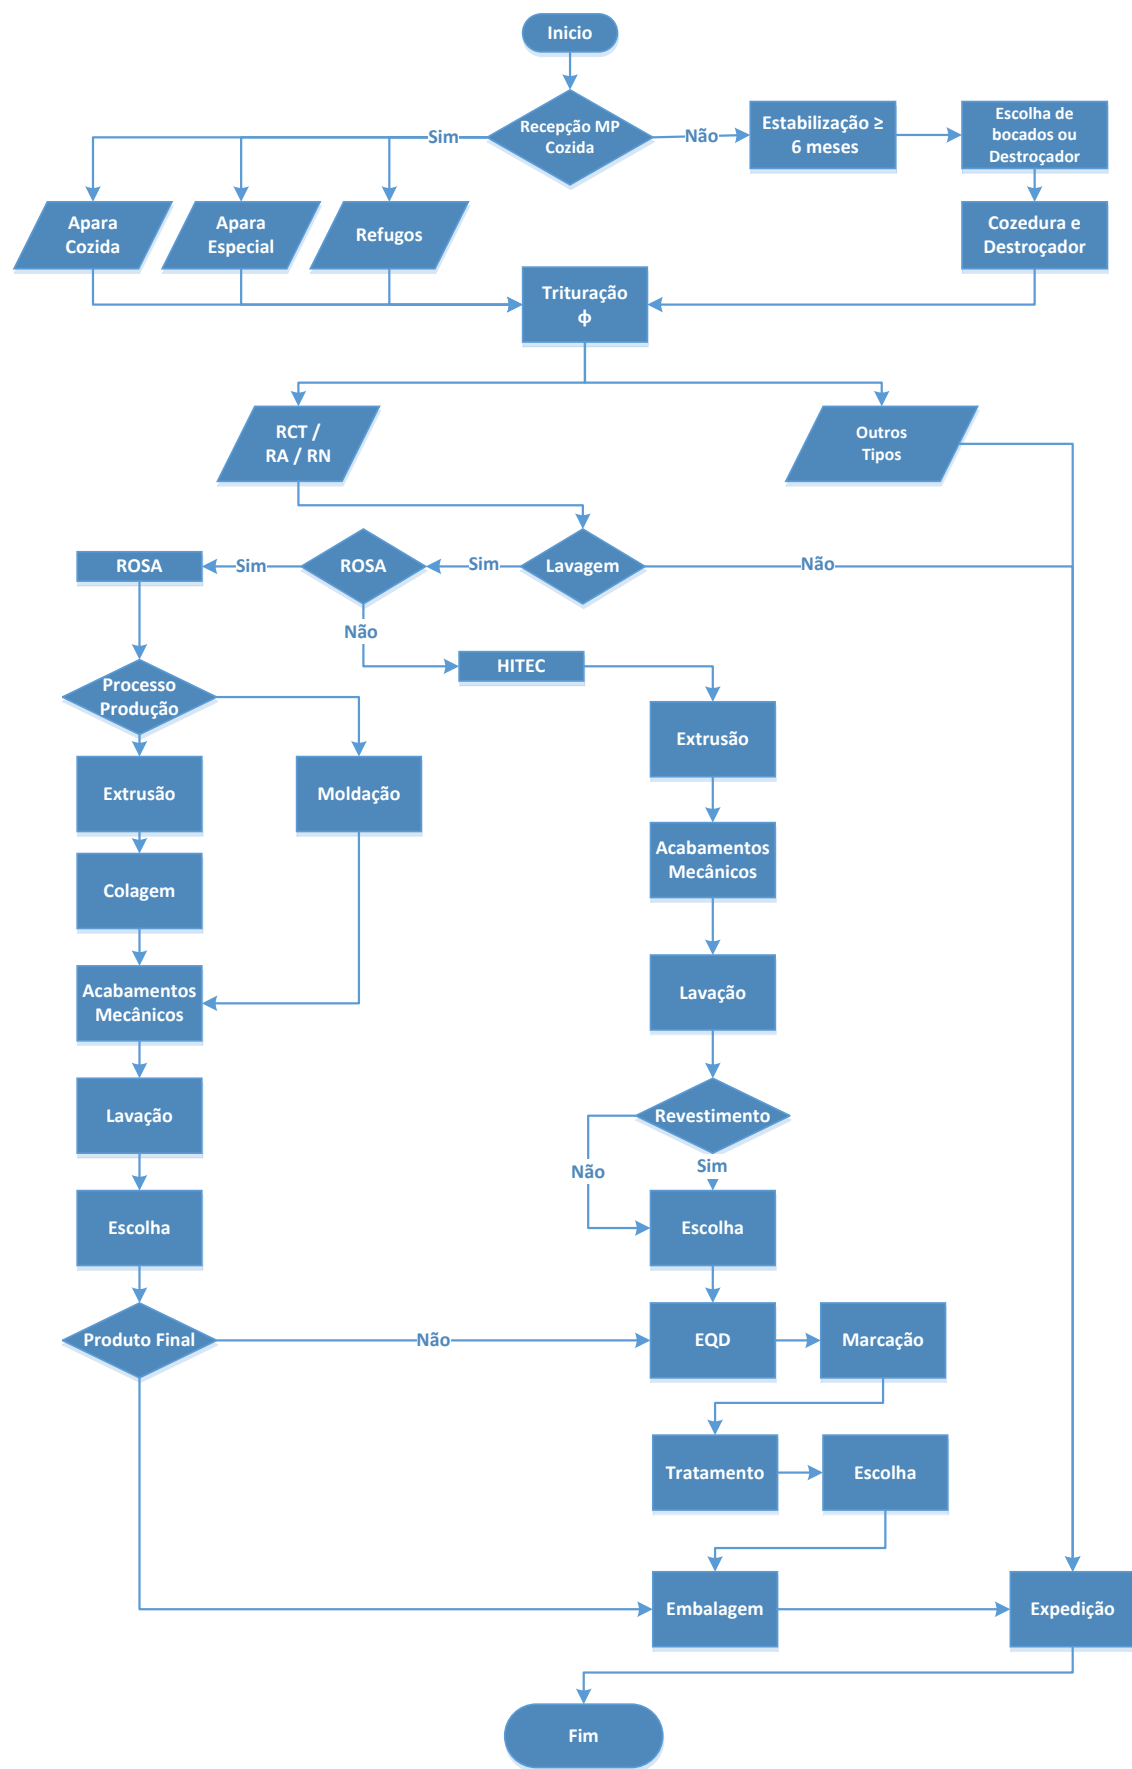


Figura 3.2 - Fluxograma, curso produtivo. EQUIPAR – Amorim & Irmãos S.A.

- **Trituração** é o processo que transforma a matéria-prima cortiça nos diferentes tipos de granulado que foram expostos anteriormente, que são repartidos para os diferentes sectores da fábrica consoante as necessidades que existam em cada um dos sectores. Nesta fase o granulado é armazenado em silos ou *big-bags*, dependendo na maior parte das vezes do facto de o seu destino ser interno ou externo (respetivamente) à unidade industrial.
- **Rosa** é o processo onde o estudo desta dissertação foi elaborado e por esse motivo será explorado em pormenor adiante. Este é o nome de um processo patenteado pela Amorim e Irmãos S.A. O seu nome advém da sigla *Rate Optimal Steam Application* e tem como objetivo fornecer um tratamento ao granulado de cortiça para extrair o TCA (2,4,6-tricloroanisol). Note-se que o TCA é um composto aromático considerado responsável pela depreciação da qualidade do vinho.
- **Sector TT** é onde são produzidas rolhas técnicas a partir de granulado de cortiça. As rolhas são fabricadas através de processos de extrusão ou moldação e os discos são colados através de um aglutinador próprio no corpo das rolhas. Após esta fase as rolhas poderão ser sujeitas a tratamentos estruturais, tais como retificação ou acabamentos mecânicos, após os quais serão lavadas e por fim escolhidas. *i.e.*, serão verificadas e segregadas consoante os defeitos que contenham.
- **Sector AGLO** é onde tipicamente são produzidas as rolhas aglomeradas, sendo o processo produtivo muito parecido ao verificado no sector Twin-Top, com exceção da colagem dos discos.
- **EQD** ou EQUIPAR distribuição é o sector responsável pela marcação das rolhas, a tinta ou a fogo, pelo tratamento, embalamento e expedição das rolhas.

3.3.1 Sector e Processo ROSA

Este trata-se de um processo internacionalmente reconhecido e fundamental para a organização. Tem por objetivo extrair uma determinada molécula presente na cortiça que pode ser responsável pela contaminação do vinho. Mais concretamente, o 2,4,6 tricloroanisol, comumente conhecido como TCA. Esta molécula provoca a depreciação da qualidade do vinho uma vez que afeta as suas características sensoriais, nomeadamente o odor e o gosto. A fim de combater estas potenciais contaminações, têm surgido diversos estudos no sentido de combater este malefício e no caso da Corticeira Amorim utiliza-se o processo ROSA™.

O sector que alberga este processo, também denominado de ROSA, envolve várias operações sequenciais: extração com vapor, secagem e estabilização, as quais se encontram dispostas no fluxograma que se segue, após o qual será dada uma breve explicação, sobretudo acerca do processo ROSA RCT.

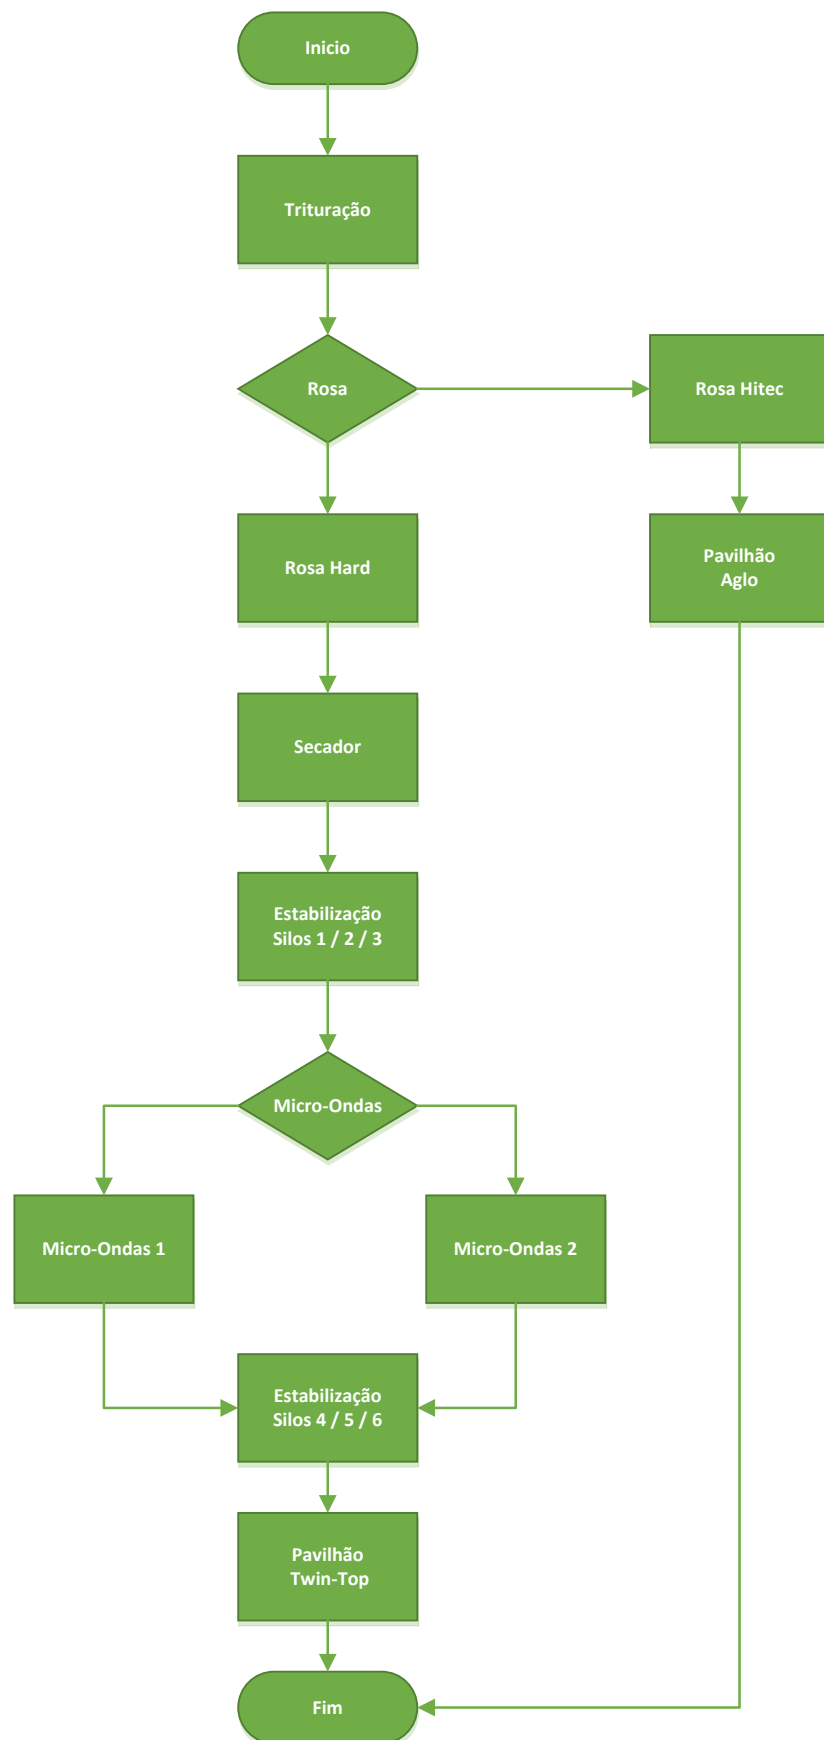


Figura 3.3 - Fluxograma Rosa RCT, EQUIPAR – Amorim & Irmãos S.A.

1. O granulado proveniente dos silos da **trituração** vai diretamente para o sistema de limpeza do granulado (ROSA ou ROSA HITEC), a menos que exista alguma anomalia na secção da trituração. Se for esse o caso, o sistema será abastecido por *Big-Bags*. O ROSA (ou Rosa Hard no caso dos grupos que limpam o RCT) é constituído por 5 grupos distintos, cada um destes contendo dois tubos que injetam vapor e limpam o granulado.
2. De seguida, após sair dos grupos do Rosa Hard o granulado passa diretamente para o **secador**. Este equipamento é constituído por um tambor cilíndrico rolante e um permutador que permite a entrada de ar quente no tambor. Esta estrutura faz com que o granulado de cortiça seque à medida que vai atravessando o tambor.
3. Após a passagem do granulado no secador, este é armazenado num de três silos (silos 1, 2 e 3) onde repousa a fim de atingir o seu estado estabilizado. A organização refere que o ideal é que neste ponto o granulado estabilize cerca de 16 - 24 horas de forma a que atinja as suas condições ótimas de massa volúmica e humidade para passar á fase seguinte sem comprometer a sua estrutura celular ao longo do processo.
4. Após o granulado passar a fase de estabilização, este é dividido e entra num dos dois **micro-ondas** equitativamente. O foco desta dissertação prende-se exatamente com o processo de passagem de granulado pelos micro-ondas. A função de ambos os micro-ondas é recuperar os valores de massa volúmica e humidade que se verificavam no granulado de cortiça antes de este ter sido submetido ao processo de lavação. O granulado é transportado de forma sequencial através dos micro-ondas, recorrendo a um tapete rolante, através dos seus fornos de forma sequencial. Estes micro-ondas encontram-se em paralelo, pelo que poderão trabalhar simultaneamente ou alternadamente, partilhando apenas a sua fonte de alimentação. Os dois micro-ondas não são idênticos, uma vez que foram adquiridos pela organização em alturas distintas. O micro-ondas 2 é o equipamento mais recente, contudo tem provado ser o mais problemático e menos resiliente, motivo esse pelo qual não entrou para o estudo desta dissertação. Sublinha-se neste ponto que no decorrer do estudo foram elaborados alguns cálculos que estabelecessem uma relação entre a potência incidente por Kg de granulado debitado do micro-ondas para caracterizar e entender melhor o processo alvo.
 - ❖ Recorre a diversos magnetrons, que são essencialmente válvulas eletrónicas que transformam a energia elétrica em ondas eletromagnéticas, para atuar sobre o granulado.
 - ❖ Essencialmente, este equipamento trata-se de um túnel destinado a secar o granulado de cortiça, através da passagem do mesmo ao longo de um conjunto de fornos distintos recorrendo a uma esteira de polipropileno. Este equipamento permite a regulação da potência de micro-ondas e da velocidade de transporte da esteira (tapete).
5. Após a passagem pelos micro-ondas o granulado repousa e estabiliza uma vez mais por um período de 16-24 horas idealmente num de três silos (silos 4, 5 e 6), período após o qual o granulado entrará na fase seguinte do processo produtivo na secção Twin-Top.

É importante referir que nesta secção existem múltiplos pontos de controlo do granulado, servindo essas recolhas para analisar diversas características tais como a granulometria, níveis de TCA, massa volúmica e a humidade relativa do granulado. No âmbito deste estudo, foram recolhidas amostras à saída do micro-ondas 1 para aferição dos níveis de massa volúmica corrigida e humidade relativa do granulado. Os métodos de aferição desses mesmos níveis serão expostos em seguida.

3.4. Método de Amostragem

Na secção ROSA, naquilo que alude ao processo alvo diretamente ligado ao estudo, *i.e.*, Rosa RCT existem três equipamentos de medição essenciais para o controlo de qualidade na secção, dos quais dois foram eleitos dois considerados fundamentais e adequados para a execução do trabalho prático nesta dissertação. A recolha do granulado era feita à saída do micro-ondas 1 recorrendo a um recipiente de borracha, e a partir desse granulado era recolhida uma amostra a ser utilizada em cada um dos equipamentos utilizados para a dissertação (balança eletrónica e balança de humidade)

- **Balança eletrónica (e cubo com dimensão de 1 dm³).** Este equipamento, recorrendo ao cubo, permite aferir automaticamente a massa volúmica do granulado a partir de uma determinada amostra.
- **Balança com secador de infravermelhos.** Este equipamento permite aferir a humidade relativa do granulado de cortiça em poucos minutos. Aquecendo o granulado de cortiça o equipamento retira a humidade ao granulado. Analisando a diferença de pesos, o equipamento faz uma estimativa percentual da humidade relativa do granulado.
- **Higrómetro com elétrodo de copo.** Este equipamento mede essencialmente a humidade superficial do granulado. Aplicando uma força de compressão no granulado, a humidade presente nos mesmos é libertada e medida através de um sensor que ao contactar com um elétrodo presente no instrumento consegue fornecer uma estimativa da humidade percentual do granulado. Este equipamento é menos preciso do que a balança de humidade, sendo utilizado apenas nalguns casos, cada vez mais esporádicos.

Os dados recolhidos diretamente a partir destes equipamentos foram utilizados para realizar os cálculos inerentes à realização da presente dissertação.

4. Componente Experimental

O presente capítulo irá apresentar as fases pelas quais este estudo passou, através da aplicação das técnicas que foram explanadas até ao momento.

Depois de analisar o processo em causa, por indicação dos responsáveis pela engenharia de processo e pela organização, tentando caracterizar o mesmo passou-se a um estudo mais penetrante do mesmo. Isto significa que primeiro foi necessário entender quais eram os fatores que afetavam o processo e quais as diferenças que existiam, nomeadamente em termos de matéria-prima.

De seguida passou-se à fase de melhoria do processo. Aplicou-se o DOE para tentar perceber quais eram os melhores níveis dos fatores das variáveis do processo sobre os quais o Micro-Ondas operava, tendo como prioridade uma principalmente uma melhoria ao nível da massa volúmica corrigida.

Na fase seguinte passou-se à implementação controlo estatístico de processo univariado e multivariado.

4.1. Desenhos de Experiências

4.1.1 Caracterização das Diferenças na Matéria-Prima

Os engenheiros da organização, por trabalharem diariamente com o processo em causa e já possuírem alguma sensibilidade na matéria, tinham fortes suspeitas da existência de diferenças significativas dentro da mesma matéria prima. Nomeadamente, para o granulado guardado nos silos, existiam fortes suspeitas da diferença de granulados quando o silo se encontrava no início, no meio e no fim de consumo.



Figura 4.1 - Representação de Silos ROSA

Numa primeira fase foi importante perceber se existiam diferenças significativas entre o próprio granulado e se fosse esse o caso, prová-lo. Nomeadamente, tentar inferir se existiam diferenças

significativas no granulado, em termos de massa volúmica corrigida e de humidade, à saída do micro-ondas tendo em conta se estava a ser utilizado granulado da parte inicial de descarga do silo, do meio ou do fim.

Para tal, efetuaram-se os testes de hipóteses dispostos, no Anexo III – Testes de hipóteses, necessários para perceber se as médias eram significativamente diferentes, procurando discernir todos estes casos. Começou por analisar-se o granulado à entrada dos micro-ondas e chegou-se às seguintes conclusões:

- Humidade relativa: a partir dos dados da organização é possível inferir que existem diferenças significativas da humidade média relativa do granulado quando este está na fase de fim de consumo de um determinado silo, em comparação com qualquer uma das outras duas possíveis fases. Já o granulado que vai para o micro-ondas 1 (MO1) na fase inicial de consumo de um determinado silo, ou a meio do consumo, não apresenta diferenças significativas em termos da humidade média.
- Massa volúmica corrigida: curiosamente, ao contrário do que se verifica ao analisar a humidade relativa, o granulado apresenta características médias semelhantes entre todas as suas fases à entrada do MO1.




Figura 4.2- Entrada MO. Diferenças estatísticas (média) entre fases do silo para humidade relativa




Figura 4.3 - Entrada MO. Diferenças estatísticas (média) entre fases do silo para massa volúmica corrigida a 8%

Já à saída do micro-ondas 1, os resultados foram um pouco distintos como se pode ver através dos resultados dispostos no Anexo III – Testes de hipóteses.

- Humidade relativa: apesar de à entrada do MO o granulado ser aparentemente idêntico, após o mesmo granulado passar pelo MO1 tornou-se significativamente diferente entre si, comparando todas as 3 fases de consumo entre si.
- Massa Volúmica Corrigida: o granulado apenas é idêntico, em termos médios, comparando a fase de início com a de meio de consumo, sendo distinto entre si para os outros casos.




Figura 4.4- Saída MO. Diferenças estatísticas (média) entre fases do silo para humidade relativa




Figura 4.5 - Saída MO. Diferenças estatísticas (média) entre fases do silo para massa volúmica corrigida a 8%

Uma vez que no caso da humidade relativa todos os casos eram significativamente diferentes entre si e no caso da massa volúmica corrigida apenas o granulado associado ao início de consumo de silo e meio de consumo de silo não eram significativamente diferentes, a decisão tomada foi a de executar as experiências apenas com o granulado do “meio”, essencialmente por três motivos. Em primeiro lugar, o granulado que se encontra a meio do silo é tipicamente o granulado que mais vezes se encontra dentro dos parâmetros de especificação para aquele ponto do processo, tanto em termos de humidade relativa como em termos de massa volúmica

corrigida. Em segundo lugar, tipicamente o granulado na fase de início e de fim de consumo do silo tende a vir misturado com bastante pó, o que tem a ver com o facto de o pó que vai caindo entre os grãos de cortiça no silo ficar aglomerado na parte mais próxima do solo do mesmo, o que contagia de certo modo o granulado na fase de início de consumo e por outro lado, o pó que fica preso à parede do silo à medida que este vai esvaziando, tende a ir caindo para cima do granulado quando o silo começa a ficar desocupado, o que faz com que na fase final de consumo também existam vestígios de pó no granulado. Em terceiro lugar, o micro-ondas trabalha a maior parte do tempo com o granulado na fase de meio de consumo, uma vez que esta fase é mais longa do que as outras duas. Assim sendo, uma vez que esta é a fase mais representativa do processo sobre os três ângulos, foi a fase escolhida para recolher o material para as experiências, tendo em vista diminuir o efeito de ruído presente no processo. Note-se também que a organização tem criado iniciativas no sentido de procurar trabalhar apenas com granulado nesta fase de consumo, sendo provavelmente este o futuro na organização, pelo que faz todo o sentido realizar o estudo nesta fase de consumo tendo em conta o seu objetivo. Frisa-se uma vez mais que Todos os testes estatísticos realizados desta fase estão disponíveis no Anexo III – Testes de hipóteses.

4.1.2 Fase de Amostragem

Durante a fase de amostragem optou-se por retirar amostras à saída do micro-ondas aproximadamente de 15 em 15 minutos. Isto teve como objetivo garantir que as condições no interior do micro-ondas tinham tempo estabilizar entre mudanças de parametrização, nomeadamente garantir que a temperatura no interior dos fornos atingia a temperatura característica de cada uma das parametrizações utilizadas. No ponto de recolha eram retiradas amostras para medição de massa volúmica e humidade relativa, uma vez que é através destes dois testes que tradicionalmente se controla o processo neste ponto. Foram definidos 3 níveis distintos para o fator potência e 5 para o fator velocidade.

4.1.3 Resultados e Verificação dos Pressupostos

Os dados obtidos a partir da amostragem encontram-se dispostos na Tabela 4.1, pela respetiva ordem padrão. Foi a partir destes mesmos dados que os pressupostos da análise de variância foram verificados e foi também através dos mesmos que os desenhos de experiências foram executados.

Frisa-se neste ponto que a metodologia sequencial de execução dos desenhos de experiências é análoga aos quatro desenhos aplicados no âmbito desta dissertação, *i.e.*, realizou-se uma verificação dos pressupostos de variância. De seguida passou-se à execução da análise de variância e das superfícies de resposta para determinar quais os melhores níveis a serem utilizados.

Tabela 4.1 - Resultados DOE 1 (Massa Volúmica)

Factor		Resposta MV		
Potência (W)	Velocidade(m/min)	Y ₁	Y ₂	Y ₃
P3	V1	64,60	64,72	63,59
P3	V2	67,07	64,48	64,79
P3	V3	70,14	70,24	67,65
P3	V4	70,96	74,27	69,61
P3	V5	77,82	77,85	76,87
P2	V1	64,72	65,44	66,01
P2	V2	68,61	64,33	67,49
P2	V3	71,23	69,91	70,60
P2	V4	75,15	72,85	75,08
P2	V5	77,47	79,28	79,13
P1	V1	66,56	66,11	66,40
P1	V2	73,24	71,19	70,21
P1	V3	71,37	70,36	74,19
P1	V4	75,00	77,48	75,06
P1	V5	76,85	78,02	80,57

De forma a validar os resultados do DOE foi necessário verificar se os pressupostos da análise de variância não eram infringidos.




Figura 4.6 - Verificação da Normalidade residual para DOE1 (Massa Volúmica)




Figura 4.7 - Verificação da homogeneidade residual para DOE1 (Massa Volúmica)



Figura 4.8 - Verificação da independência para DOE1 (Massa Volúmica)

Analisando os gráficos considerou-se que, razoavelmente, nenhum dos pressupostos foi fortemente violado.

De seguida, procedeu-se à análise de variância para este fatorial completo de dois fatores a vários níveis referente à característica massa volúmica. Os resultados vêm apresentados na Tabela 4.2 ANOVA:

Tabela 4.2 - ANOVA para DOE1 (Massa Volúmica)

ANOVA						
Fonte de variação	SS	g.l.	MS	F_0	$F_{\text{crítico, 5\%}}$	p
Potência	4,19	2	2,09	0,41	3,32	0,67
Velocidade	916,50	4	229,12	44,98	2,69	0,00
Potência x Velocidade	13,24	8	1,65	0,32	2,27	0,95
Erro	152,81	30	5,09	-	-	-
Total	1086,730	44	-	-	-	-

Comparando os valores da estatística de teste F_0 associados a cada um dos fatores com os respetivos valores críticos constata-se que apenas o fator velocidade aparenta ser significativo. Este facto é comprovado analisando a superfície de resposta (Figura 2.2).




Figura 4.9 - Superfície de resposta DOE1 (Massa Volúmica)

Para escolher os melhores níveis, tem-se em conta que a potência (gerida pelo número de magnetrons) não é significativa. Uma vez que a potência não é significativa, nem a interação entre fatores, o número de magnetrons escolhido deverá ser o mais económico para a organização. Assim sendo, tendo em conta o pedido original da equipa da organização, analisando o DOE tendo como foco a diminuição da distância entre os valores medidos e o *target* a combinação de melhores níveis, o resultado é o disposto na Tabela 4.3. A análise de distância ao target encontra-se disposta no Anexo IV – Cálculos DOE.

Tabela 4.3 - Melhores Níveis DOE1 (Massa Volúmica)

Magnetrons	Velocidade
+ Económico	V3

Seguindo o mesmo raciocínio, foi executado o DOE 2 que consistiu na realização de um estudo análogo ao que foi realizado no DOE1, embora que colocando agora o foco na humidade relativa. A recolha de amostras para o estudo do DOE2 foi recolhida, simultaneamente, enquanto se fazia a recolha para o DOE1.

Tabela 4.4 - Resultados DOE2 (Humidade Relativa)

Factor		Resposta MV		
Potência (W)	Velocidade(m/min)	Y ₁	Y ₂	Y ₃
P3	V1	3,68	2,71	4,25
P3	V2	5,8	6,13	5,99
P3	V3	7,68	6,48	7,25
P3	V4	9,07	8,28	9,54
P3	V5	79	79,2	82,2
P2	V1	4,73	5,19	4,96
P2	V2	7,99	8,38	8,02
P2	V3	8,73	7,99	7,47
P2	V4	9,03	10,04	8,75
P2	V5	9,09	9,95	8,2
P1	V1	4,76	3,91	6,6
P1	V2	9,07	8,14	9,79
P1	V3	8,3	8,83	6,88
P1	V4	8,37	7,19	7,8
P1	V5	9,24	9,37	6,99




Figura 4.10 - Verificação da normalidade residual para DOE2 (Humidade Relativa)




Figura 4.11 - Verificação da homogeneidade residual para DOE 2 (Humidade Relativa)




Figura 4.12 - Verificação da independência DOE2 (Humidade Relativa)

Tabela 4.5 - ANOVA para DOE2 (Humidade Relativa)

ANOVA						
Fonte de variação	SS	g.l.	MS	F ₀	F _{crítico, 5%}	p
Potência	2,58	2	1,29	1,65	3,32	0,21
Velocidade	128,89	4	32,22	41,21	2,69	0,00
Potência x Velocidade	31,61	8	3,95	5,05	2,27	0,00
Erro	23,46	30	0,78	-	-	-
Total	186,545	44	-	-	-	-

Uma vez mais os pressupostos da análise de variância não aparentam ser violados. Analisando a ANOVA é possível verificar que o fator “velocidade” e a combinação “Potência - Velocidade” são significativos, facto corroborado pela superfície de resposta apresentada na Figura 4.13.




Figura 4.13 - Superfície de resposta DOE2 (Humidade Relativa)

Seguindo uma linha de raciocínio análoga à apresentada no DOE1, focando agora na melhoria dos valores de humidade, os melhores níveis são dados pelos resultados dispostos na Tabela 4.6 atentando ao facto de neste caso a combinação dos fatores ser significativa.

Tabela 4.6 - Melhores Níveis DOE2 (Humidade Relativa)

Magnetrons	Velocidade
P1	V5

De seguida, foram elaborados mais dois desenhos de experiências análogos. Foram estudadas as mesmas características da qualidade, no mesmo processo, recolhendo o mesmo número de amostras. Contudo o arranjo do desenho foi parcialmente modificado uma vez que os níveis foram alterados, *i.e.*, níveis do DOE1 distintos dos utilizados no DOE3 e níveis do DOE2 distintos do seu homólogo DOE4. Também foi diminuída a raseira que controla a altura do granulado no tapete, de forma a que o granulado tivesse uma altura menor no tapete, para averiguar se existiria alguma diferença nos resultados.

Os resultados desta segunda etapa encontram-se dispostos na Tabela 4.7.

Tabela 4.7 - Resultados DOE3 (Massa Volúmica)

Factor		Resposta MV		
Potência (W)	Velocidade(m/min)	Y ₁	Y ₂	Y ₃
P3	V1	64,9	65,7	63,8
P3	V2	69,4	65,1	65,1
P3	V3	69,2	67,9	69,6
P3	V4	71,6	72,1	71,1
P3	V5	69,8	69,9	71,0
P2	V1	63,3	66,6	67,6
P2	V2	66,2	67,4	68,2
P2	V3	69,5	69,1	67,6
P2	V4	69,8	69,9	70,8
P2	V5	75,9	72,3	74,0
P1	V1	64,7	68,7	66,4
P1	V2	68,3	70,7	69,4
P1	V3	66,9	70,6	69,3
P1	V4	77,7	75,3	75,4
P1	V5	77,6	77,1	77,1

E então, realizou-se o mesmo procedimento:




Figura 4.14 - Verificação da Normalidade DOE 3 (Massa Volúmica)




Figura 4.15 - Verificação da homogeneidade da variância DOE 3 (Massa Volúmica)




Figura 4.16 - Verificação da independência DOE 3 (Massa Volúmica)

Uma vez mais os pressupostos de desenho de experiência não aparentam ser violados.

Tabela 4.8 - ANOVA DOE3 (Massa Volúmica)

ANOVA						
Fonte de variação	SS	g.l.	MS	F ₀	F _{crítico, 5%}	p
Potência	0,36	2,00	0,18	0,03	3,32	0,97
Velocidade	414,41	4,00	103,60	15,32	2,69	0,00
Potência x Velocidade	7,81	8,00	0,98	0,14	2,27	1,00
Erro	202,85	30,00	6,76	-	-	-
Total	625,433	44	-	-	-	-

À semelhança do que aconteceu no desenho homólogo (DOE1), a velocidade é uma vez mais o único fator significativo. Fator corroborado através da superfície de resposta da Figura 4.17. Seguiu-se o raciocínio análogo para decidir quais eram os melhores níveis.




Figura 4.17 - Superfície de resposta DOE3 (Massa Volúmica)

Assim sendo, os melhores níveis encontram-se apresentados na Tabela 4.9

Tabela 4.9 - Melhores níveis DOE3 (Massa Volúmica)

Magnetrons	Velocidade
+ Económico	V4

Seguiu-se então, por fim, o último desenho de experiências, DOE 4 (homólogo ao DOE2):

Tabela 4.10 - Resultados DOE4 (Humidade Relativa)

Factor		Resposta Humidade Relativa		
Potência (W)	Velocidade(m/min)	Y ₁	Y ₂	Y ₃
P3	V1	4,1	2,5	3,4
P3	V2	8,2	6,1	5,3
P3	V3	7,1	8,0	5,2
P3	V4	6,6	7,4	8,8
P3	V5	9,9	10,4	8,3
P2	V1	5,6	2,4	2,8
P2	V2	4,9	6,5	4,3
P2	V3	9,4	7,5	9,9
P2	V4	10,3	9,2	10,7
P2	V5	9,7	10,1	11,7
P1	V1	6,1	3,6	5,7
P1	V2	8,4	9,6	8,3
P1	V3	9,3	7,8	6,3
P1	V4	8,1	8,6	8,7
P1	V5	9,4	10,3	8,3




Figura 4.18 - Verificação da normalidade DOE4 (Humidade Relativa)




Figura 4.19 - Verificação homogeneidade da variância DOE4 (Humidade Relativa)




Figura 4.20 - Verificação da independência DOE4 (Humidade Relativa)

Uma vez mais, considera-se que os pressupostos da análise de variância não eram violados, pelo que se passou ao cálculo da ANOVA correspondentes, disposta na Tabela 4.11.

Tabela 4.11 - ANOVA DOE 4 (Humidade Relativa)

ANOVA						
Fonte de variação	SS	g.l.	MS	F ₀	F _{crítico, 5%}	p
Potência	7,6931	2	3,85	0,5885	3,32	0,561438
Velocidade	28,3305	4	7,08	1,0836	2,69	0,382219
Potência x Velocidade	27,6535	8	3,46	0,5289	2,27	0,825284
Erro	196,0842	30	6,54	-	-	-
Total	259,761	44	-	-	-	-

Neste último caso, como se pode verificar, nenhum fator (ou combinação) é significativo. Este facto poderá ter-se sucedido devido a alterações sistemáticas das condições climáticas à data deste DOE, o que resulta num valor elevado do quadrado médio do erro, MS_{Erro}. A melhor combinação dos níveis será a mais conveniente para a organização, tendo em conta os níveis dos fatores experimentados.

Comparando as variâncias dos dados da organização, como disposto no Anexo III – Testes de hipóteses no ponto relativo à

Comparação de desenhos durante os períodos em que se realizaram os desenhos de experiências com a raseira no nível 1 e no nível 2, nota-se que em termos de massa volúmica as variâncias são significativamente diferentes, ao passo que em termos de humidade não o são. Uma vez que a organização dá prioridade à massa volúmica, concluiu-se que a opção mais viável tendo como critério a variabilidade do processo é a utilização da raseira no nível 2. Foi com base nesse resultado que o estudo de controlo estatístico de processo univariado e multivariado foi elaborado.

4.2. Cartas de Controlo, Estudo Univariado

A aplicação das cartas de controlo deve suceder-se após a aplicação do DOE devido à necessidade conceitual que esta possui de ser aplicada numa fase em que a variabilidade processo seja reduzida e/ou as condições de operação não sejam alteradas. Assim sendo, este SPC foi aplicado fixando as condições de operação definidas através do DOE1 que foi realizado e considerado como a melhor solução encontrada até ao momento. Uma vez mais o controlo foi realizado no ponto de saída do micro-ondas, tanto para a humidade relativa como para a massa

volúmica. Os dados provaram ser auto correlacionados, como fica demonstrado em seguida, pelo que se teve de atuar de acordo com esta situação.

Frisa-se neste ponto que em todos os ciclos iterativos serão apresentados apenas o primeiro e último passo, passando pela explicação do processo em si. Os ciclos completos encontram-se expostos no

Anexo V – Processo Univariadas. Todos os procedimentos aqui apresentados foram executados recorrendo aos softwares Statistica e Microsoft Office (Excel).

4.2.1 Independência dos Dados

Tal como previamente referido, a independência dos dados deve ser verificada através da análise dos correlogramas associados a cada uma das características da qualidade. Os respetivos correlogramas finais encontram-se dispostos a partir da Figura 4.21 à Figura 4.24. Os correlogramas correspondentes a todas as iterações efetuadas encontram-se no Anexo V.




Figura 4.21 - FAC (Massa Volúmica)




Figura 4.22 - FACP (Massa Volúmica)




Figura 4.23 - FAC (Humidade)




Figura 4.24 - FACP (Humidade)

Analisando os correlogramas iniciais dispostos facilmente se verifica que os dados relativos a ambas as características da qualidade se encontram auto correlacionados através dos critérios expostos na Tabela 2.7, realizando a respetiva análise, uma vez que em ambas as FACE e FACPE as funções não se encontram contidas nos intervalos de confiança, tal como é possível verificar através do Anexo V. Assim sendo, foi necessário executar uma modelação ARIMA. Para definir os parâmetros de modelação correta foi utilizado método apresentado por Box *et al* (2008). Através deste método, chegou-se á conclusão que ambos os modelos que mais se adequam são autorregressivos. Tanto a massa volúmica como a humidade relativa inicialmente ajustavam-se a um modelo AR (2). Após as diversas iterações dispostas no Anexo V chegou-se aos parâmetros do processo adequados, que por sua vez se adequavam ambos a um modelo AR (1,0,0).

Os parâmetros do processo são então dados por:

Tabela 4.12 - Parâmetros do processo para Massa Volúmica e Humidade Relativa

Característica	ξ	Φ_1	ρ_1
Massa Volúmica	28,90	0,59	0,59
Humidade Relativa	3,02	0,66	0,27

4.2.2 Cartas de Controlo Univariadas

Após a modelação se encontrar por fim elaborada, entrou-se na Fase 1 da construção das cartas de controlo univariadas, nomeadamente das cartas e-MR aplicadas aos resíduos de ambas as características da qualidade.

Como foi enunciado durante a contextualização teórica, numa primeira fase é importante estimar os parâmetros do processo. Para o fazer, é necessário garantir em primeiro lugar que o processo (através dos seus dados) se encontra sob controlo estatístico. Este é um processo iterativo, descrito através dos seguintes passos:

Passo 1. Construção das cartas de controlo e-MR para os resíduos obtidos no final da modelação do modelo ARIMA correspondente a uma determinada característica da Qualidade.

Passo 2. Análise das cartas de controlo para garantir que não existem causas especiais de variação. Caso não existam causas especiais considera-se que o processo se encontra sobre controlo estatístico e o processo iterativo encerra neste ponto. Caso contrário é necessário executar os passos 3 e 4 que se seguem.

Passo 3. Trocar os dados de previsão na série original, *i.e.*, substituir os valores correspondentes às causas especiais de variação pelos valores previstos nesse instante.

Passo 4. Modelar novamente o processo e voltar a executar o processo a partir do passo 1

Uma vez mais, todos os raciocínios de modelação intermédios encontram-se no Anexo V. Em seguida é possível observar os gráficos finais obtidos para a Fase 1 das cartas de controlo, recolhidos diretamente a partir do software.

Ao longo do processo iterativo foram elaboradas diversas modelações e houve diversos pontos relativos às características em modificados ao longo do processo, massa volúmica (57, 68, 76) e humidade relativa (pontos 17, 76, 77 e 86).

As figuras em causa podem ser verificadas em seguida, da Figura 4.25 à figura Figura 4.28, onde se podem verificar então as cartas de controlo finais de cada uma das características da qualidade para a fase 1:

- Carta de controlo dos resíduos para a massa volúmica
- Carta de controlo das médias móveis para a Massa Volúmica
- Carta de controlo dos resíduos para a Humidade
- Carta de controlo das médias móveis para a Humidade




Figura 4.25 - Carta de Controlo Resíduos, Fase 1 (Massa Volúmica)




Figura 4.26 - Carta de Controlo Médias Móveis, Fase 1 (Massa Volúmica)




Figura 4.27 - Carta de Controlo Resíduos, Fase 1 (Humidade)




Figura 4.28 - Carta de Controlo Médias Móveis, Fase 1 (Humidade)

Como se pode verificar nas cartas de controlo e-MR para a massa volúmica e humidade, todos os pontos encontram-se dentro dos limites de controlo pelo que se considera que o processo se encontra sob controlo estatístico. Assim sendo, os passos seguintes são a verificação da Normalidade dos dados (resíduos) e a verificação da independência dos dados após a modelação. Sublinha-se, uma vez mais, que este é um processo iterativo e os correlogramas que serão apresentados de seguida correspondem aos obtidos após a iteração final. Os histogramas utilizados encontram-se no Anexo V.

Tabela 4.13 - Resultados teste de normalidade univariadas

D_{crítico} ($\alpha = 5\%$)	0,089
D_{Kolmogorov-Smirnov} MV	0,062
D_{Kolmogorov-Smirnov} Humidade	0,060

O teste de Normalidade foi executado utilizando o teste de Kolmogorov-Smirnov disponível no software Statistica. Como se pode verificar na tabela acima, ambas as variáveis apresentam uma distribuição Normal para os seus resíduos uma vez que o valor de D para ambas as variáveis é inferior ao valor D crítico. A fórmula de cálculo do valor D crítico encontra-se disposta no Anexo II – Tabelas e Fórmulas Estatísticas. Os correlogramas finais dos resíduos para as características massa volúmica e humidade encontram-se dispostos nos correlogramas da Figura 4.29 à Figura 4.32.




Figura 4.29 - FACE Final (Massa Volúmica)




Figura 4.30 - FACPE Final (Massa Volúmica)




Figura 4.31 - FACE Final (Humidade)




Figura 4.32 - FACPE Final (Humidade)

Como se pode verificar pelos correlogramas há evidência dos resíduos serem independentes.

Por fim, foi necessário estimar os parâmetros do processo e verificar a sua capacidade, que como se pode ver pela Tabela 4.14, estão todos dentro dos valores aceitáveis.

Tabela 4.14 - Especificações e Capacidades, Massa Volúmica Corrigida e Humidade Relativa

Capacidade do processo		
Variável	Massa Volúmica	Humidade Relativa
LSE	81	13,5
LIE	59	3,5
Cp	1,51	1,65
(Cpk) _i	1,60	1,47
(Cpk) _s	1,43	1,83
Cp _k	1,43	1,47

Uma vez que ambos os valores de CPk são superiores a 1,33 assumiu-se que o processo tem capacidade para produzir dentro das especificações e assim sendo entrou-se na Fase 2, apesar

de o processo se encontrar descentrado uma vez que C_{pk} e C_{pk} s não são idênticos para nenhuma das características da qualidade.

Nesta fase foram recolhidos novos dados para as cartas de controlo dos erros de previsão, tendo em conta os parâmetros definidos a partir da Fase 1 através do modelo ARIMA. As cartas de controlo da Fase 2 são apresentados nas figuras Figura 4.33 a **Erro! A origem da referência não foi encontrada..** Estes segundos cálculos foram executados recorrendo ao software Excel. Note-se que os limites de controlo começam com uma ligeira curvatura, devendo-se ao período de estabilização do cálculo.




Figura 4.33 - Carta de Controlo Erros de Previsão, Massa Volúmica, Fase 2




Figura 4.34 - Carta de Controlo Amplitudes Móveis, Massa Volúmica, Fase 2




Figura 4.35 - Carta de Controlo Erros de Previsão, Humidade, Fase 2




Figura 4.36 - Carta de Controlo Amplitudes Móveis, Humidade, Fase 2

Note-se que não existem quaisquer pontos fora dos limites de controlo, *i.e.*, não existem causas especiais de variação.

4.3. Cartas de Controlo, Estudo Multivariado

4.3.1 Fase 1 do Estudo Multivariado

Tal como se sucede para o controlo de estatístico de processo univariado, o estudo multivariado do processo também se divide na fase 1 e na fase 2. Note-se que agora através do estudo multivariado vai ser possível controlar as duas características da qualidade simultaneamente (massa volúmica corrigida e humidade). Note-se também que no estudo multivariado também é possível considerar a correlação das características da qualidade que se pretendem controlar, tendo a vantagem de se poder considerar também qualquer correlação que possa existir entre as mesmas. Para construir as cartas de controlo multivariadas poderão ser tomados os seguintes passos, algo semelhantes ao demonstrado no processo de execução univariado:

Passo 1. Construir da carta T^2 para os resíduos da modelação ARIMA correspondente às características da qualidade que se pretendem calcular.

Passo 2. Caso não existam causas especiais, considera-se que o processo multivariado se encontra sob controlo estatístico e o processo encerra neste ponto. Contudo, se existirem pontos fora dos limites de controlo deverão ser executados os passos 3 e 4. Para detectar as causas especiais de variação será utilizado o “método aplicando a estatística d ” referenciado por Pereira e Requeijo (2012), onde a estatística d é dada para cada variável j pela expressão que se segue:

$$d_j = T^2 - T_{(j)}^2, \text{ com } j = 1, 2, \dots, p \quad (4.1)$$

Note-se que $T_{(j)}^2$ representa o valor da estatística de Hotelling, excluindo a variável j . Considera-se que uma determinada variável contribui significativamente para uma determinada situação fora de controlo quando $d_j > \chi_{\alpha;1}^2$. É importante frisar que quando nenhuma das variáveis satisfaz esta equação para um determinado ponto fora de controlo, essa situação poderá estar a ocorrer devido à correlação existente entre as variáveis e devem ser substituídas ambas as variáveis.

Passo 3. Caso existam causas especiais de variação, os respetivos valores deverão ser substituídos na série de dados original, *i.e.*, deverão ser substituídos os valores na série original pelos valores previstos.

Passo 4. Modelar novamente o processo e regressar ao passo 1.

Ao contrário do que se passou no caso das cartas univariadas, o processo executou-se todo no através do software Excel. A carta de controlo que se obteve para a Fase 1 encontra-se na Figura 4.37. Frisa-se uma vez mais que este é um processo iterativo que contempla várias modelações.

Foram modificados diversos pontos ao longo do processo para cada uma das características da qualidade, tanto a massa volúmica (57, 68, 76, 80, 86) como para a humidade relativa (77, 78, 79, 80).




Figura 4.37 - Carta de Controle T^2 , Massa Volúmica Corrigida e Humidade, Fase 1

Como se pode verificar através desta carta final da Fase 1, o processo encontra-se sob controlo estatístico de processo. É importante sublinhar que neste ponto, assumindo esta asserção, tal como sucedeu no controlo estatístico univariado é necessário verificar os pressupostos do controlo estatístico de processo. Uma vez mais, os valores de D das características demonstram ser inferiores ao D crítico pelo que se considera que os dados apresentam uma distribuição Normal.

Tabela 4.15 - Resultados teste de normalidade multivariadas

D crítico:	0,089
D k-s MV:	0,050
D k-s Humidade:	0,060

A independência foi verificada do mesmo modo que para o estudo univariado. Para não expor raciocínios redundantes neste processo, uma vez que é análogo ao praticado anteriormente, o processo encontra-se completamente exposto no Anexo VI – Processo Multivariadas . Note-se que neste caso a humidade corresponde a um modelo AR(2) e a massa volúmica corrigida a um modelo AR(1).

Estimados os parâmetros do processo, foi possível partir para o estudo da capacidade multivariada do processo, para os mesmos limites de especificação apresentados no caso das cartas univariadas.

Tabela 4.16 - Resultados capacidade para cartas multivariadas

Índices de capacidade		
CpM	PV	LI
1,98	0,97	1,00

Como se pode verificar, o processo é capaz e encontra-se suficientemente centrado.

4.3.2 Fase 2 do Estudo Multivariado

Posto isto, passa-se finalmente à Fase 2 da carta de controlo de T^2 , representada na Figura 4.38




Figura 4.38 - Carta de Controlo T^2 , Massa Volúmica Corrigida e Humidade, Fase 2

Como se pode observar existem 4 pontos fora de controlo. Nomeadamente, usando o método da estatística d:

- Pontos 5, 65 e 81 devido a valores irregulares da humidade
- Ponto 13 provavelmente devido à correlação entre variáveis

4.4. Confronto de resultados

Tabela 4.17 - Causas especiais substituídas, Estudo Univariado vs Estudo Multivariado, Fase 1

Estudo	Massa Volúmica Corrigida	Humidade Relativa	Correlação entre Variáveis
Univariado	57, 68, 76	17, 76, 77, 86	-
Multivariado	57, 68, 76, 80	77, 78, 79, 80	86

Relativamente à Fase 1, tanto no estudo univariado como no estudo multivariado foi necessário proceder a diversas iterações de forma a que fosse possível encontrar o modelo correto para os dados em estudo.

No caso da massa volúmica, tal como se pode verificar através da Tabela 4.17, no estudo multivariado, foram encontradas 4 causas especiais de variação, das quais 3 eram as mesmas encontradas no caso do estudo univariado. No caso da humidade, foram encontradas 4 causas de variação em ambos os casos embora que a maior parte dos pontos sejam distintos, existindo apenas o ponto 77 em comum.

4.4.1 Fase 2 do Estudo Multivariado

Na fase 2, ao passo que no estudo univariado não foi detetada nenhuma causa especial de variação, no estudo multivariado foram identificados quatro pontos fora de controlo, como ficou demonstrado através da Figura 4.38.

Uma vez que a carta de controlo multivariada apresenta ser a mais sensível e face ao objetivo da organização reduzir a variabilidade existente no seu processo geral, a carta de controlo multivariada T^2 demonstra ser a mais adequada para ser aplicada.

4.5. Diagrama de Ishikawa

Ao longo de toda a execução prática das experiências e das cartas de controlo, foram sendo registadas as potenciais fontes da variação verificada no processo. Esta recolha foi feita com base na observação do dia-a-dia no terreno e com base nas informações que iam sendo fornecidas por todos os colaboradores da fábrica (gestão de topo, equipas funcionais de engenharia, chefias e operadores).

Através das informações recolhidas, dispendo a mesma sobre 6 eixos distintos considerados tradicionais (Mão de obra, meio ambiente, equipamento, medições, materiais e métodos), foi então desenvolvido um Diagrama de Ishikawa que representa todas as causas potenciais da variabilidade que normalmente está presente no processo. O diagrama encontra-se na Figura 4.39.

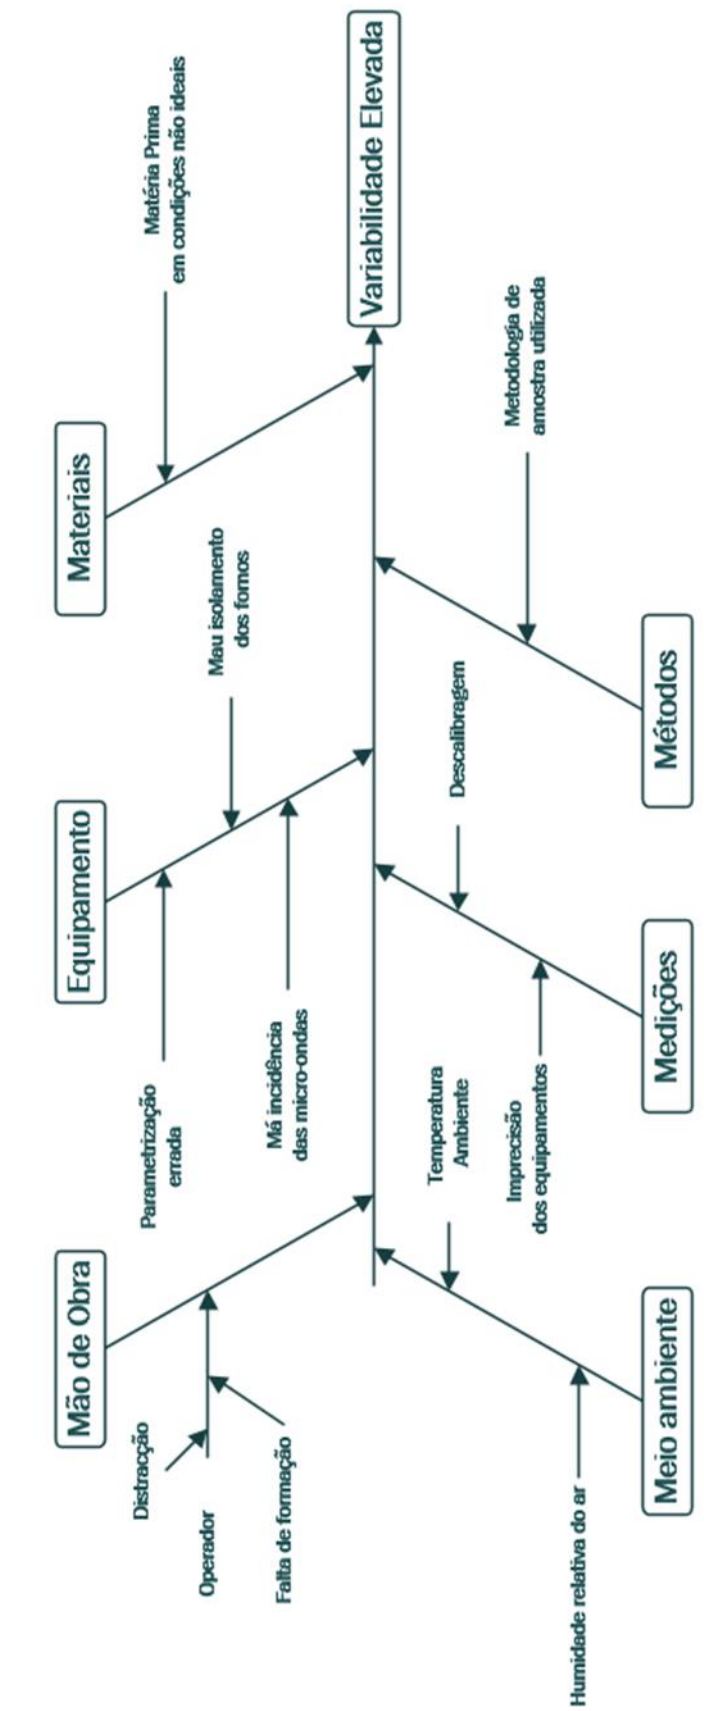


Figura 4.39 - Diagrama de Ishikawa, Causas da variabilidade elevada existente no MO1

5. Conclusão

Este capítulo pretende apresentar um breve sumário das principais ilações que foram inferidas a partir das técnicas que foram aplicadas ao longo do estudo executado no âmbito da presente dissertação. Pretende-se também apresentar algumas sugestões de ações a implementar assim como de estudos a realizar no futuro com base nos resultados obtidos e com base nalgumas dificuldades que surgiram ao longo da execução do estudo, que são consideradas benéficas para a organização.

É importante frisar que a contextualização teórica da tese foi elaborada com base numa seleção prudente das fontes, procurando sempre recorrer a autores de peso nas temáticas basilares para as técnicas aqui aplicadas.

5.1. Resultados e Ilações

O método de investigação utilizado na presente dissertação teve sempre como foco a aplicação de técnicas associadas ao planeamento e controlo estatístico do processo, nomeadamente através da aplicação de desenho de experiências (fatorial completo) e cartas de controlo capazes de lidar com a existência de autocorrelação para realizar tanto o estudo univariado como o multivariado. Estas técnicas interligaram-se profundamente com as necessidades da EQUIPAR – Amorim & Irmãos S.A. uma vez que o a processo de produção de rolhas de cortiça a partir de granulado é por si só um processo complexo e exigente, onde existem diversas variáveis a controlar em tempo real e muitas potenciais fontes de variação a atuar em simultâneo. O controlo de processo torna-se neste tipo de casos uma ferramenta fundamental para que se tenha um processo capaz, fluído e eficiente.

Este estudo, como já foi referido no capítulo 3, foi executado na unidade industrial EQUIPAR – Amorim & Irmãos S.A., em Coruche, mais em concreto, no processo ROSA onde se desenrola o processo (que dá a origem ao nome do pavilhão) caracterizado por várias etapas sequenciais. Escolheu-se controlar duas características da qualidade (massa volúmica e humidade) à saída do micro-ondas um (MO1) de entre as várias características da qualidade em estudo na organização.

O objetivo passou por perceber quais eram as melhores condições de operação para o micro-ondas 1 atendendo às condições sobre as quais o processo se encontrava e definir parâmetros de operação para essas mesmas condições. Passou também por implementar cartas de controlo capazes de controlar o processo em causa e se possível que fossem capazes de controlar as duas características simultaneamente. Por fim, mas não com menos importância, pretendia-se fazer também um estudo da capacidade do processo. Assim sendo, por necessidade da organização e após alguns debates sobre potenciais formas de procurar resolver os problemas presentes, chegou-se à conclusão que a aplicação de técnicas de planeamento e controlo estatístico de processos seriam uma forma útil e benigna de explorar as questões levantadas.

Através das ferramentas em causa, e através da engrenagem gerada entre conceitos teóricos e práticos, foi possível aplicar um método consistente que provou, assim como tem sido comprovado na literatura, ser capaz de trazer resultados benéficos e uteis.

O primeiro passo passou pela implementação de quatro desenhos de experiências distintos, em que o DOE 1 e 2 eram homólogos do 3 e 4 mudando entre eles apenas a posição da raseira na entrada do micro-ondas 1. Uma vez que o micro-ondas 1 tinha apenas dois fatores controláveis, optou-se pela aplicação de um DOE de 2 fatores a vários níveis (3 e 5 níveis), perfazendo um total de 15 combinações a estudar por DOE, o que corresponde por sua vez a 45 ensaios por DOE uma vez que foram executadas 3 replicações por experiência. Por fim foram implementadas as cartas de controlo para fazer face às necessidades de controlo ao longo do processo que uma unidade industrial como a EQUIPAR tem, considerando a dimensão e complexidade do seu processo em adição à responsabilidade que a organização tem para com o seu cliente final.

Através da implementação dos desenhos de experiências 1 e 3 pretendeu estudar-se a massa volúmica corrigida, ao passo que os desenhos de experiências 2 e 4 pretendiam estudar a humidade relativa. Ao alterar o nível da raseira de entre o primeiro e o segundo DOE de 10 filetes do parafuso regulador (dimensão usual) para 4 filetes, a altura que o granulado assume no tapete rolante que atravessa o micro-ondas altera-se, ficando mais baixa. Ao implementar esta alteração, tentou-se perceber se existiam diferenças significativas em termos de variabilidade uma vez que existia a suspeita que este facto poderia condicionar a variabilidade do processo. Ao realizar os testes estatísticos chegou-se à conclusão que existiam diferenças significativas, pelo que deveriam ser tomadas as opções mais económicas, *i.e.*, deveriam ser implementadas as soluções que fossem mais adequadas para os desenhos de experiências correspondentes ao nível da raseira utilizados nos desenhos 3 e 4. Por sua vez, uma vez que a organização, à data da realização do estudo, privilegiou os resultados obtidos para a massa volúmica e o resultado do DOE 4 não permite tirar ilações, a solução ótima encontrada correspondia à utilização do nível de velocidade mais económico para a empresa e a fixação da potência, regulada através dos magnetrons do aparelho, no nível 3 da configuração utilizada no DOE3. Com os resultados foi ainda possível expor e caracterizar perante a organização a existência de uma relação praticamente direta entre inputs e outputs do micro-ondas.

O estudo univariado e multivariado do processo foi executado no mesmo lugar em que as amostras são tradicionalmente recolhidas na organização, de forma a que os operadores pudessem através das cartas obtidas atuar no processo em tempo real, impedindo que existisse produto não conforme a jusante do processo produtivo. Uma vez que após a passagem pelos micro-ondas o granulado estabiliza entre 16 a 24 horas existe tempo suficiente para segregar o material em causa caso seja necessário.

Como se pôde constatar no capítulo anterior verificou-se a existência de autocorrelação para as características da qualidade em estudo, que iriam ser as variáveis a controlar. Isto forçou a execução de uma modelação matemática dos dados que fosse capaz de retirar o efeito da autocorrelação dos dados e as cartas de controlo dos resíduos dos dados pudessem ser

corretamente elaboradas. Na prática, no caso do estudo univariado, isto implicou a construção das cartas dos resíduos e amplitudes móveis para cada uma das características, nas respetivas Fases 1, e a construção das cartas dos erros de previsão e das amplitudes móveis associadas a esses erros nas respetivas Fases 2. O estudo da carta multivariada implicou a construção da carta T^2 . Uma vez mais, ressalta-se que teve de ser executado um processo iterativo, tanto no caso univariado como no multivariado, de modelação dos dados de cada vez que registasse a existência de pontos fora de controlo durante a Fase 1 qualquer uma das cartas elaboradas. Note-se que as cartas multivariadas encontraram causas especiais de variação não identificadas no estudo univariado, pelo que demonstraram a capacidade de aplicar um controlo mais apertado e preciso do processo. Uma vez que se pretende avaliar as duas variáveis em conjunto, este é mais um argumento a favor da implementação do controlo estatístico multivariado do processo na organização.

5.2. Sugestões de Melhoria

Uma das principais dificuldades prendeu-se com o facto de existir uma enorme variabilidade presente no processo, devido à reatividade da matéria-prima a elementos externos.

As causas conducentes a esta variabilidade elevada podem ser avaliadas através de um Diagrama de Ishikawa, também designado por Diagrama Espinha-de-peixe (devido ao *design* característico) ou ainda diagrama de causa-e-efeito. Esta ferramenta é aplicada a problemas que mereçam estudos mais aprofundados, permitindo analisar as causas potenciais que podem originar um determinado problema final (Ishikawa, 1982). Neste caso o problema em causa é a variabilidade verificada no do MO1.

O diagrama em causa encontra-se representado na Figura 4.39 e foi elaborado com base em 6 origens potenciais, tal como foi referido anteriormente:

- Mão de obra
- Meio ambiente
- Equipamento
- Medições
- Materiais
- Métodos

Para anular algumas destas potenciais fontes de variação, atendendo ao facto de a especificação necessária para que o processo seja classificado de “capaz” ser demasiado lata tendo em conta as necessidades do produto final, sugere-se que a empresa aplique um conjunto de medidas pensadas ao longo da execução da dissertação, tendo como fim a melhoria do controlo de qualidade dos seus processos e da qualidade do produto final, apesar do esforço contínuo que é executado para procurar garantir redução da variabilidade e o aumento da fluidez e eficiência do processo por parte da organização. As sugestões pensadas, tendo como base os problemas

identificados e visualizados ao longo do tempo, que culminam no diagrama da **Erro! A origem d a referência não foi encontrada.** passam por:

- Garantir que o tempo de estabilização do granulado dentro dos silos seja cumprido.
- Utilização de equipamentos de medição nos silos para que permitam a aferição da humidade relativa e a massa volúmica do granulado em tempo real, permitindo perceber exatamente quando é que o granulado se encontra em condições de continuar o processo produtivo.
- Implementação de equipamentos no micro-ondas que permitam a medição e controlo em tempo real das suas características da qualidade, permitindo que seja obtida uma maior quantidade de dados mais fidedignos, sem intervenção de fatores externos que poderão induzir variabilidade, como o caso da intervenção manual para recolha de amostras por parte dos operadores. Esta solução libertaria também os operadores para executar outro tipo de tarefas necessárias na organização.
- Isolamento das vias de passagem e de armazenamento do granulado. O meio ambiente tem um forte impacto nas condições da cortiça. É imperativo que este fator seja controlado para se poder executar o processo com as especificações (mais apertadas) que são necessárias.
- Execução de mais estudos técnicos acerca do próprio micro-ondas. É importante avaliar o próprio equipamento, por parte de especialistas externos, para garantir que o mesmo está a funcionar nas condições mais adequadas para a execução da sua função. Nomeadamente perceber como é que o mesmo poderia realizar um controlo automático dos seus parâmetros tendo em conta os dados que seriam recebidos automaticamente. A curto-prazo, sugere-se que a metodologia de amostragem seja alterada. Uma única amostra do granulado demonstrou não ser representativa do granulado envolvente num determinado momento. Por vezes, recolhendo diversas amostras seguidas, existiam diferenças substanciais nas características da qualidade do mesmo. Assim sendo, a constituição ou técnica de amostragem deveria ser revista pela organização para implementar um método mais representativo de amostragem, tal como o aumento da frequência de amostragem ou o aumento do número de amostras de granulado de cortiça retiradas por cada momento de recolha. No entanto, tal como foi frisado no segundo ponto, a utilização de tecnologia que permita a monitorização em tempo real seria o ideal.
- Sugere-se também que seja executado um plano de manutenção mais apertado não apenas do micro-ondas, mas também dos equipamentos de medição. Os magnetrons, isoladamente, tendem a ficar desativados com alguma regularidade por diversos motivos (e.g. maus contactos, cabos queimados, pó nos quadros elétricos) pelo que um plano de manutenção apertado seria fulcral para que o micro-ondas execute corretamente a sua função. Isto é particularmente importante se se tiver em conta que o micro-ondas é um aparelho fundamental para que o granulado atinja as condições ideais para o processo a jusante. Por vezes também se verificou que existiam diversos erros por descalibragem dos próprios equipamentos de medição, pelo que uma manutenção mais regular a estes equipamentos também demonstrou ser fulcral.

- Sugere-se também a utilização de software próprio, capaz de criar e analisar cartas de controlo multivariadas de forma mais expedita para que possa ser feita uma análise mais regular e mais profunda das tendências, das causas especiais de variação (tendências, pontos fora de controlo) não só por parte dos operadores, mas também por parte da equipa de engenharia.

5.3. Sugestões para Trabalhos Futuros

Como nota conclusiva, é importante afirmar que embora durante a execução prática desta dissertação tenha sido feito um esforço constante no sentido de seleccionar os métodos mais adequados e executar tudo da forma mais minuciosa possível, todas as técnicas têm pontos cegos e imperfeições que podem ser complementados e aperfeiçoados respetivamente. A aplicação deste tipo de metodologias é por si só uma forma de aprendizagem acerca do processo e devem ser vistas enquanto um processo de engrenagem iterativo, com muitas combinações a explorar, no qual os resultados obtidos e a experiência levam a novas execuções de maior sucesso e mais proveitosas.

Assim sendo, findo este trabalho, ficam algumas sugestões de estudos futuros que complementem o trabalho que foi realizado até ao momento:

- Recomenda-se uma nova aplicação do desenho de experiências no MO1. Os DOE's foram aplicados num período de alterações climáticas. Apesar de ter sido feito o maior esforço possível para garantir que os resultados não eram influenciados pelo "ruído", é importante frisar que seria da maior utilidade para a organização começar a realizar os estudos em quartos de ano, i.e., realizar DOE's no pico de cada uma das estações para entender exatamente quais os melhores parâmetros a utilizar em cada altura. Isto significa que também deveria existir um estudo de validação para os resultados obtidos nesta dissertação. Seria razoável ponderar também a hipótese de aplicar um desenho de experiências sobre a forma de fatorial fracionado, incluindo mais fatores para tentar conhecer melhor a influência ou não influência de outros fatores no processo.
- Apesar se não ter existido a oportunidade de o fazer à data da realização desta dissertação, seria importantíssimo executar desenhos de experiências que permitam determinar as condições necessárias para que não existam diferenças significativas (em termos de humidade e massa volúmica) entre os granulados provenientes do micro-ondas 1, do micro-ondas 2 e do HITEC. Isto visa garantir que a fábrica opera toda, sincronizadamente, sobre as condições ideais de granulado.
- Muita da variabilidade presente nos dados esta relacionada com processos a montante do chamado ROSA, isto é, a montante da trituração (inclusive). Assim sendo, sugere-se que sejam executados estudos semelhantes ao desta dissertação nas áreas da fábrica anteriores tendo em vista a redução da variabilidade, assim como a consideração da possibilidade de realização de um estudo ligado à seleção de fornecedores e matérias-primas.

- Seria também importante realizar um estudo ligado aos custos de não qualidade existentes na fábrica, nomeadamente ligados à produção, segregação e/ou reprocessamento de material não conforme na fábrica, para servir de apoio à tomada de decisão por parte da gestão de topo da organização quanto a novos investimentos a realizar na unidade industrial.

O tipo de estudos como o que foi realizado nesta dissertação é fundamental para o processo de atualização e inovação dentro de uma organização. Apesar de todos os benefícios que estas técnicas possam oferecer, é imperativo garantir que existam as condições adequadas para as aplicar. Nomeadamente, a redução da variabilidade existente no processo é uma condição imperativa, não só para a aplicação correta das ferramentas, mas também para a garantia de qualidade no produto final e também para a eficiência e sucesso da organização. Os valores de variação indesejáveis estiveram presentes ao longo da execução desta dissertação e tende a fazer parte do processo produtivo geral da EQUIPAR, afetando de forma significativa o produto ao longo do processo. É importante que a organização investigue e invista em métodos que permitam controlar a variabilidade existente no processo. Como diria Platão, “a necessidade é a mãe da inovação”. Por si só, as ferramentas não trarão isoladamente, na maior parte das vezes, benefícios significativos à organização. É necessário aplicar as mesmas de forma cíclica, procurando sempre melhorar com base nos resultados anteriores. Também é necessário que a organização esteja toda focada e envolvida nos projetos de melhoria continua tendo em vista o sucesso da organização, o que será benéfico para todos os elementos envolvidos, pois trará novas formas mais eficientes de executar o trabalho e aumentar os níveis de qualidade.

6. Referências Bibliográficas

Alder, B. J., & Wainwright, T. E. (1970). Decay of the velocity autocorrelation function. *Physical Review A*, 18–21.

Alwan, L. C., & Roberts, H. V. (1988). Time-Series Process Modeling for Statistical Control. *Journal of Business Economics and Statistics*, 87–95.

Amhemad, A. Z. (2010). Effect of non normality on statistical control charts. *ICNIT 2010 - 2010 International Conference on Networking and Information Technology*, 512–515.

Badiru, A.B. (2014). Handbook of Industrial and Systems Engineering, 2ª Edição, Taylor & Francis Group.

Benneyan, J. C., Lloyd, R. C., & Plsek, P. E. (2003). Statistical process control as a tool for research and healthcare improvement, 458–465. Retrieved from <http://qualitysafety.bmj.com>.

Box, G. E. P., Jenkins, G. M., & Reinsel, G. C. (2008). *Time series analysis*.

Craig, C. C., & Fisher, R. a. (1936). The Design of Experiments. *The American Mathematical Monthly*, 43(3), 180.

Chandra, M.J. (2001) Statistical Quality Control. Department of Industrial and Manufacturing Engineering, Pennsylvania State University.

Chakraborty, S., Laan, P. e Barkir, S.T. (2001). “*Non parametric Control Charts: An overview and Some Results*”, Journal of Quality Technology, Vol.33, pp.304-315.

Claro, F. A. E., Costa, A. F. B., & Machado, M. A. G. (2008). Double sampling control chart for a first order autoregressive process. *Pesquisa Operacional*, 28(3), 545–562.

Craig, C. C., & Fisher, R. a. (1936). The Design of Experiments. *The American Mathematical Monthly*.

Crawley, M.J. (2005). Statistics: an introduction using R. Imperial College of London. Wiley & Sons.

De Mast, J., & Does, R. J. M. M. (2006). Industrial statistics: A discipline with opportunities and challenges. *Statistica Neerlandica*, 60(3), 270–282.

Deming, W.E. (1951) Statistical Techniques in Industry as a Natural Resource. Bulletin of the International Statistics Institute, Vol. XXXIII : Part V

Deming, W. E. (1953). Statistical techniques in industry. *Adv Manage*, 18(11), 8–12.

Deming, W.E. (1962). Some Statistical Principles for Efficient Design of Surveys and Experiments. Encyclopedia of Statistical Sciences.

Deming, W.E. (1986), *Out of the Crisis*, Center for Advanced Engineering Study, Cambridge, MA: Massachusetts Institute of Technology.

Devore, J.L. (2016). Probability and Statistics for Engineering and Sciences, California Polytechnic State University.

Edward Jackson, J. (2007). Multivariate quality control. *Communications in Statistics - Theory and Methods*, 14(11), 2657–2688.

Harris, T. J., & Ross, W. H. (1991). Statistical process control procedures for correlated observations. *Canadian Journal of Chemical Engineering*, 69(1), 48–57.

Hietschold, N., Reinhardt, R., & Gurtner, S. (2014). Measuring critical success factors of TQM implementation successfully – a systematic literature review. GEN.

Ishikawa, K. (1982). Guide to Quality Control, McGraw-Hill, New York.

Jackson, J. E. (2007). *Communications in Statistics - Theory and Methods Multivariate quality control*.

Juran, J. M. (1999). *Juran's Quality Control Handbook*, 5ª Edição, McGraw-Hill, New York.

Juran, J.M., Gryna Jr, F.M. (1980). Quality Planning and Analysis, 2º Edição, McGraw-Hill, New Delhi.

Journal, S., Statistical, A., Sep, N., & Draper, N. R. (2014). A Basis for the Selection of a Response Surface Design Author (s): G . E . P . Box and Norman R . Draper A BASIS FOR THE SELECTION OF A RESPONSE SURFACE DESIGN *, 54(287), 622–654.

- Kennard, R. W., & Stone, L. A. (1969). Computer Aided Design of Experiments. *Technometrics*, 11(1), 137–148.
- Koutras, M. V., Bersimis, S., & Maravelakis, P. E. (2007). Statistical process control using shewhart control charts with supplementary runs rules. *Methodology and Computing in Applied Probability*, 9(2), 207–224.
- MacGregor, J. F., & Kourti, T. (1995). Statistical process control of multivariate processes. *Control Engineering Practice*, 3(3), 403–414.
- Macgregor, J. F., & Kourt, T. (1995). Statistical Process Control of Multivariate Processes, 3(3), 403–414.
- Mast, J. d. (2008). "A history of industrial statistics and quality and efficiency improvement. In T. G. S. Coleman", *Statistical Practice in Business and Industry*, John Wiley & Sons, Ltd, West Sussex, pp. 14-27.
- Mitra, A. (2008). *Fundamentals of Quality Control and Improvement*, 3ª Edição, John Wiley & Sons, New Jersey.
- Mendenhall, W. Beaver, R. Beaver, B. (2013). Introduction to Probability and Statistics, BROOKS/COLE Cengage Learning.
- Montgomery, D. C. (2013a). Design and Analysis of Experiments, 8ª Edição, John Wiley & Sons, New York.
- Montgomery, D. (2013b). Introduction to Statistical Quality Control, 7ª Edição, John Wiley & Sons, New York.
- Muller, D. (1995). Sucessões Cronológicas e Previsão, Departamento de Matemática – ISEG, Universidade Técnica de Lisboa.
- Oakland, J. (2003). Statistical Process Control, 5ª Edição. Oxford: Butterworth-Heinemann.
- Pereira, Z.L. e Requeijo, J.G. (2012), Qualidade: Planeamento e Controlo Estatístico de Processos, 2ª Edição, FCT-UNL, Lisboa

- Requeijo, J. G. (2004). *Técnicas Avançadas do Controlo Estatístico do Processo*, Tese de Doutoramento, Faculdade de Ciências e Tecnologia - Universidade de Lisboa, Lisboa.
- Reynolds, M. R., & Lu, C. (1997). Control Charts for Monitoring Processes With Autocorrelated Data. *Nonlinear Analysis, Theory, Methods and Applications*, 30(7), 4059–4067.
- Sharma, N. K., & Cudney, E. A. (2011). Signal-to-Noise ratio and design complexity based on Unified Loss Function – LTB case with Finite Target, 3(7), 15–24.
- Shewhart, W.A. (1931). *Economic Control of Quality of Manufactures Product*, D. Van Nostrand Company, Inc, New York.
- Shumway, R. H., & Stoffer, D. S. (2011). *Time Series Analysis and Its Applications With R Examples*.
- Society, R. S. (2016). Approximate Tests of Correlation in Time-Series Author (s): M . H . Quenouille Source : Journal of the Royal Statistical Society . Series B (Methodological), Vol.11 , No.1 Published by : Wiley for the Royal Statistical Society 11(1), 68–84.
- Steiber, A., & Alänge, S. (2012). Do TQM principles need to change? Learning from a comparison to Google Inc. *Total Quality Management & Business Excellence*, 3363(April), 1–14.
- Store, J. S. A. W. (2013). INTERNATIONAL STANDARD Shewhart control charts).
- Stoumbos, Z. G., Reynolds, M. R., Ryan, T. P., & Woodall, W. H. (2000). The state of statistical process control as we proceed into the 21st century. *Journal of the American Statistical Association*, 95(451), 992–998.
- Suarez, J.G. (1992). Three Experts on Quality Management: Crosby, P. B., Deming, W. E., Juran, J. M., & Suarez, J. G., Total Quality Leadership Office, US Navy.
- Taylor, P. (2009). A New Multivariate Process Capability Vector. *Quality Engineering*, 37–41.
- Vasilopoulos, A. V., & Stamboulis, A. P. (1978). Modification of control chart limits in the presence of data correlation. *Journal of Quality Technology*, 10(1), 20–30.

Wardell, D. G., Moskowitz, H., Plante, R. D., & Wardell, D. O. N. G. (2014). Control Charts in the Presence of Data Correlation CONTROL CHARTS IN THE PRESENCE OF DATA CORRELATION, 38(8), 1084–1105.

Wei, W. W. S. (1994). Time series analysis. Univariate and Multivariate Methods, 2º Edition. Pearson - Addison Wesley

Western Electric (1956). Statistical Quality Control Handbook, Western Electric Corporation, Indianapolis.

Weiss, M. S. (1978). Modification of the Kolmogorov-Smirnov Statistic for Use with Correlated Data. *Journal of the American Statistical Association*, 73(364), 872–875.

Weiss, N.A. (2012). Introductory Statistics, 9th Edition, Pearson

Woodall, W.H. (1999). "Research Issues and Idead in Statistical Process Control". *Journal of Quality Technology*. Vol. 31, pp.376.

Woodall, W. H. (2000). "Controversies and Contradictions in Statistical Process Control". *Journal of Quality Technology* , Vol. 32, pp.341-350.

Acedido a 06 de Junho de 2016, no site da Corticeira Amorim:

<http://www.amorim.com>

Acedido a 06 de Junho de 2016, no site da Associação Portuguesa da Cortiça:

<http://www.apcor.pt/produtos/rolhas>

7. Anexos

7.1. Anexos I – Organigrama da Amorim (Rolhas)

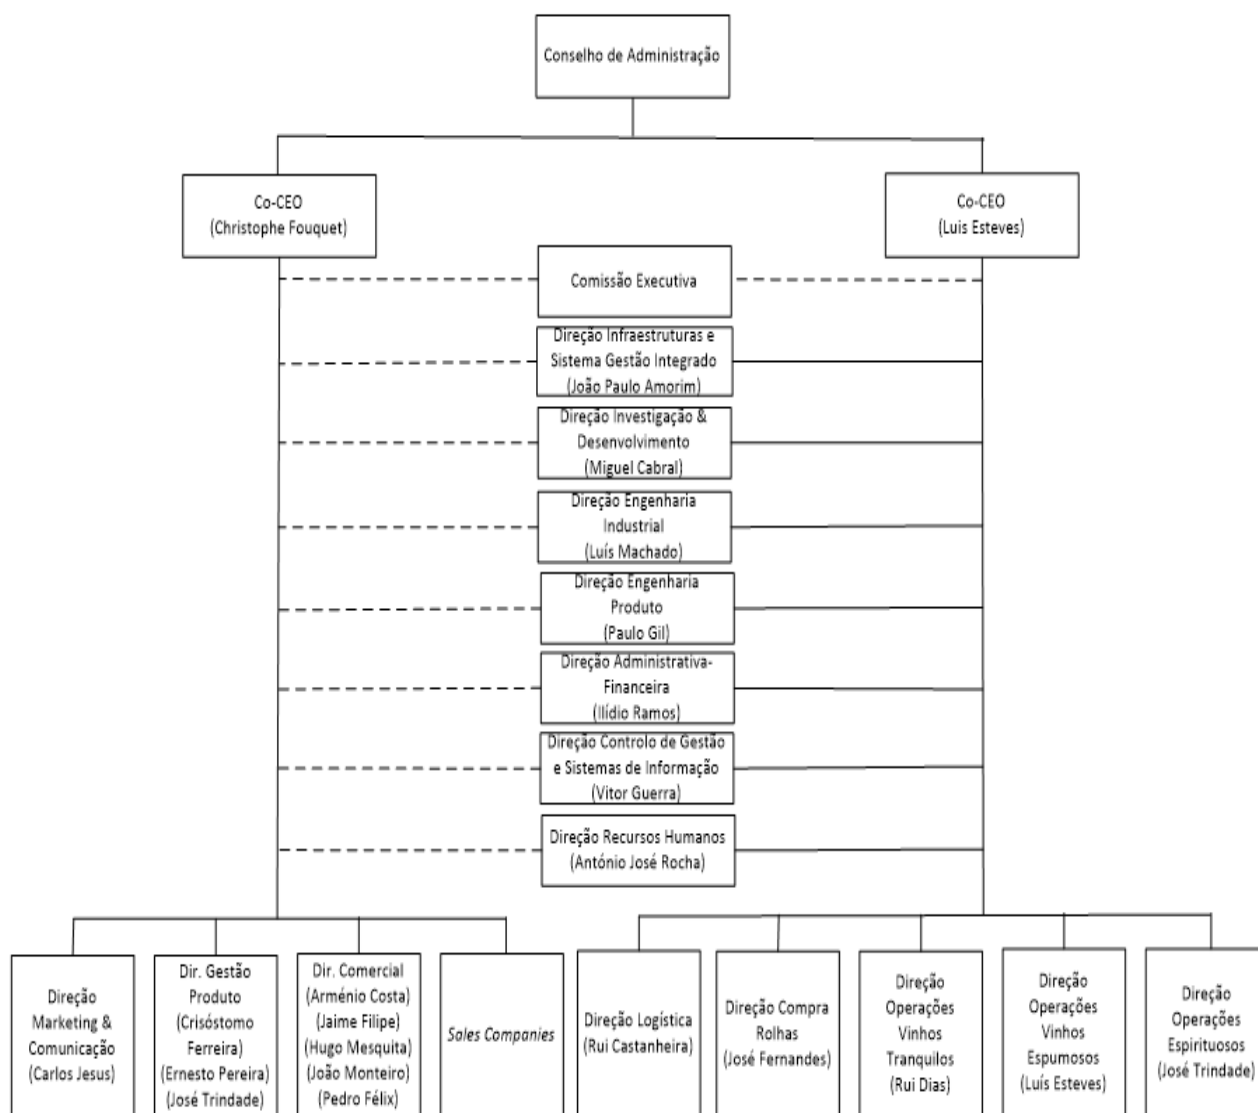


Figura 7.1 - Organigrama do Grupo Amorim (Rolhas)

7.2. Anexo II – Tabelas e Fórmulas Estatísticas

Tabela 7.1 - Critérios de interpretação do *p-value*

<i>P-Value</i>	Interpretação
$P < 0,01$	Evidência muito forte contra H0
$0,01 \leq P < 0,05$	Evidência moderada contra H0
$0,05 \leq P < 0,1$	Evidência sugestiva contra H0
$P \geq 0,10$	Pouca ou nenhuma evidência real contra H0

Tabela 7.2 – Valores críticos associados à Distribuição da Estatística D (Lilliefors).

Fonte: Pereira & Requeijo (2012)

<i>n</i>	α				
	0,20	0,15	0,10	0,05	0,01
4	0,300	0,319	0,352	0,381	0,417
5	0,285	0,299	0,315	0,337	0,405
6	0,265	0,277	0,294	0,319	0,364
7	0,247	0,258	0,276	0,300	0,348
8	0,233	0,244	0,261	0,285	0,331
9	0,223	0,233	0,249	0,271	0,311
10	0,215	0,224	0,239	0,258	0,294
11	0,206	0,217	0,230	0,249	0,284
12	0,199	0,212	0,223	0,242	0,275
13	0,190	0,202	0,214	0,234	0,268
14	0,183	0,194	0,207	0,227	0,261
15	0,177	0,187	0,201	0,220	0,257
16	0,173	0,182	0,195	0,213	0,250
17	0,169	0,177	0,189	0,206	0,245
18	0,166	0,173	0,184	0,200	0,239
19	0,163	0,169	0,179	0,195	0,235
20	0,160	0,166	0,174	0,190	0,231
25	0,149	0,153	0,165	0,180	0,203
30	0,131	0,136	0,144	0,161	0,187
30	$\frac{0,736}{\sqrt{n}}$	$\frac{0,768}{\sqrt{n}}$	$\frac{0,805}{\sqrt{n}}$	$\frac{0,886}{\sqrt{n}}$	$\frac{1,031}{\sqrt{n}}$

Tabela 7.3 - Constantes para Cartas Tradicionais de Variáveis. Fonte: Pereira e Requeijo (2012)

Factores para construção das cartas de controle de variáveis

Dimensão Amostra	Carta da Média				Carta do Desvios Padrão				Carta da Amplitude					
	Factores Limites Controle				Factores Linha Central				Factores para Limites de Controle					
	A	A ₂	A ₃	d ₂	c ₄	B ₃	B ₄	B ₅	B ₆	d ₃	D ₁	D ₂	D ₃	D ₄
2	2,121	1,881	2,659	1,128	0,7979	0	3,267	0	2,606	0,853	0	3,686	0	3,267
3	1,732	1,023	1,954	1,693	0,8862	0	2,568	0	2,276	0,888	0	4,358	0	2,574
4	1,500	0,729	1,628	2,059	0,9213	0	2,266	0	2,088	0,880	0	4,698	0	2,282
5	1,342	0,577	1,427	2,326	0,9400	0	2,089	0	1,964	0,864	0	4,918	0	2,114
6	1,225	0,483	1,287	2,534	0,9515	0,030	1,970	0,029	1,874	0,848	0	5,078	0	2,004
7	1,134	0,419	1,182	2,704	0,9594	0,118	1,882	0,113	1,806	0,833	0,204	5,204	0,076	1,924
8	1,061	0,373	1,099	2,847	0,9650	0,185	1,815	0,179	1,751	0,820	0,388	5,306	0,136	1,864
9	1,000	0,337	1,032	2,970	0,9693	0,239	1,761	0,232	1,707	0,808	0,547	5,393	0,184	1,816
10	0,949	0,308	0,975	3,078	0,9727	0,284	1,716	0,276	1,669	0,797	0,687	5,469	0,223	1,777
11	0,905	0,285	0,927	3,173	0,9754	0,321	1,679	0,313	1,637	0,787	0,811	5,535	0,256	1,744
12	0,866	0,266	0,886	3,258	0,9776	0,354	1,646	0,346	1,610	0,778	0,922	5,594	0,283	1,717
13	0,832	0,249	0,850	3,336	0,9794	0,382	1,618	0,374	1,585	0,770	1,025	5,647	0,307	1,693
14	0,802	0,235	0,817	3,407	0,9810	0,406	1,594	0,399	1,563	0,763	1,118	5,696	0,328	1,672
15	0,775	0,223	0,789	3,472	0,9823	0,428	1,572	0,421	1,544	0,756	1,203	5,741	0,347	1,653
16	0,750	0,212	0,763	3,532	0,9835	0,448	1,552	0,440	1,526	0,750	1,282	5,782	0,363	1,637
17	0,728	0,203	0,739	3,588	0,9845	0,466	1,534	0,458	1,511	0,744	1,356	5,820	0,378	1,622
18	0,707	0,194	0,718	3,640	0,9854	0,482	1,518	0,475	1,496	0,739	1,424	5,856	0,391	1,608
19	0,688	0,187	0,698	3,689	0,9862	0,497	1,503	0,490	1,483	0,734	1,487	5,891	0,403	1,597
20	0,671	0,180	0,680	3,735	0,9869	0,510	1,490	0,504	1,470	0,729	1,549	5,921	0,415	1,585
21	0,655	0,173	0,663	3,778	0,9876	0,523	1,477	0,516	1,459	0,724	1,605	5,951	0,425	1,575
22	0,640	0,167	0,647	3,819	0,9882	0,534	1,466	0,528	1,448	0,720	1,659	5,979	0,434	1,566
23	0,626	0,162	0,633	3,858	0,9887	0,545	1,455	0,539	1,438	0,716	1,710	6,006	0,443	1,557
24	0,612	0,157	0,619	3,895	0,9892	0,555	1,445	0,549	1,429	0,712	1,759	6,031	0,451	1,548
25	0,600	0,153	0,606	3,931	0,9896	0,565	1,435	0,559	1,420	0,708	1,806	6,056	0,459	1,541

Para $n > 25$

$$A = \frac{3}{\sqrt{n}} \quad A_3 = \frac{3}{c_4 \sqrt{n}} \quad c_4 \approx \frac{4(n-1)}{4n-3} \quad B_3 = 1 - \frac{3\sqrt{1-c_4^2}}{c_4} \quad B_4 = 1 + \frac{3\sqrt{1-c_4^2}}{c_4} \quad B_5 = c_4 - 3\sqrt{1-c_4^2} \quad B_6 = c_4 + 3\sqrt{1-c_4^2}$$

7.3. Anexo III – Testes de hipóteses

Note-se que para a realização dos testes de hipóteses relacionados com a média foi utilizada a estatística Z. Tal foi possível devido ao facto de existir sempre um grande número de dados (≥ 30). Nestes casos, é aceitável que seja feita uma aproximação da Distribuição *t-student* à Distribuição *Normal*.

7.3.1 Entrada do MO1

Tabela 7.4 - Teste de Hipóteses da Média para MV (Início/Meio Silo) Entrada MO1

Teste z: duas amostras para médias

	<i>Início</i>	<i>Meio</i>
Média	81,37	81,17
Variância conhecida	27,39	17,30
Observações	294,00	723,00
Hipótese de diferença de média	0,00	
z	0,59	
P(Z≤z) bi-caudal	0,56	
z crítico bi-caudal	1,96	

Tabela 7.5 - Teste de Hipóteses da Média para MV (Início/ Fim Silo) Entrada MO1

Teste z: duas amostras para médias

	<i>Fim</i>	<i>Início</i>
Média	81,20	81,37
Variância conhecida	33,03	27,39
Observações	280,00	294,00
Hipótese de diferença de média	0,00	
z	-0,38	
P(Z≤z) bi-caudal	0,70	
z crítico bi-caudal	1,96	

Tabela 7.6 - Teste de Hipóteses da Média para MV (Fim/Meio Silo) Entrada MO1

Teste z: duas amostras para médias

	<i>Fim</i>	<i>Meio</i>
Média	81,20	81,17
Variância conhecida	33,03	17,30
Observações	280,00	723,00
Hipótese de diferença de média	0,00	
z	0,06	
P(Z<=z) bi-caudal	0,95	
z crítico bi-caudal	1,96	

**Tabela 7.7 - Teste de Hipóteses da Média para Humidade Relativa (Inicio/Meio Silo)
Entrada MO1**

Teste z: duas amostras para médias

	<i>Inicio</i>	<i>Meio</i>
Média	13,06	13,03
Variância conhecida	2,24	14,23
Observações	294,00	723,00
Hipótese de diferença de média	0,00	
z	0,17	
P(Z<=z) bi-caudal	0,86	
z crítico bi-caudal	1,96	

**Tabela 7.8 - Teste de Hipóteses da Média para Humidade Relativa (Inicio/ Fim Silo)
Entrada MO1**

Teste z: duas amostras para médias

	<i>Fim</i>	<i>Inicio</i>
Média	12,02	13,06
Variância conhecida	32,80	2,24
Observações	280,00	294,00
Hipótese de diferença de média	0,00	
z	-2,93	
P(Z<=z) bi-caudal	0,00	
z crítico bi-caudal	1,96	

Tabela 7.9 - Teste de Hipóteses da Média para Humidade Relativa (Fim/Meio Silo) Entrada MO1

Teste z: duas amostras para médias

	<i>Fim</i>	<i>Meio</i>
Média	12,02	13,03
Variância conhecida	32,80	14,23
Observações	280,00	723,00
Hipótese de diferença de média	0,00	
z	-2,72	
P(Z<=z) bi-caudal	0,01	
z crítico bi-caudal	1,96	

7.3.2 Saída MO1

Tabela 7.10 - Teste de Hipóteses da Média para MV (Início/Meio Silo) Saída MO1

Teste z: duas amostras para médias

	<i>Início</i>	<i>Meio</i>
Média	70,55	69,69
Variância conhecida	7,19	5,46
Observações	302,00	762,00
Hipótese de diferença de média	0,00	
z	4,87	
P(Z<=z) bi-caudal	0,00	
z crítico bi-caudal	1,96	

Tabela 7.11 - Teste de Hipóteses da Média para MV (Início/ Fim Silo) Saída MO1

Teste z: duas amostras para médias

	<i>Fim</i>	<i>Início</i>
Média	70,32	70,55
Variância conhecida	9,12	7,19
Observações	301,00	302,00
Hipótese de diferença de média	0,00	
z	-0,96	
P(Z<=z) bi-caudal	0,34	
z crítico bi-caudal	1,96	

Tabela 7.12 - Teste de Hipóteses da Média para MV (Fim/Meio Silo) Saída MO1
Teste z: duas amostras para médias

	<i>Fim</i>	<i>Meio</i>
Média	70,32	69,69
Variância conhecida	9,12	5,46
Observações	301,00	762,00
Hipótese de diferença de média	0,00	
z	3,27	
P(Z<=z) bi-caudal	0,00	
z crítico bi-caudal	1,96	

Tabela 7.13 - Teste de Hipóteses da Média para Humidade Relativa (Inicio/Meio Silo)
Saída MO1

Teste z: duas amostras para médias

	<i>Inicio</i>	<i>Meio</i>
Média	9,77	9,55
Variância conhecida	1,98	1,61
Observações	302,00	762,00
Hipótese de diferença de média	0,00	
z	2,34	
P(Z<=z) bi-caudal	0,02	
z crítico bi-caudal	1,96	

Tabela 7.14 - Teste de Hipóteses da Média para Humidade (Inicio/ Fim Silo) Saída MO1

Teste z: duas amostras para médias

	<i>Fim</i>	<i>Inicio</i>
Média	8,90	9,77
Variância conhecida	2,72	1,98
Observações	301,00	302,00
Hipótese de diferença de média	0,00	
z	-6,97	
P(Z<=z) bi-caudal	0,00	
z crítico bi-caudal	1,96	

Tabela 7.15 - Teste de Hipóteses da Média para Humidade Relativa (Fim/Meio Silo) Saída MO1

Teste z: duas amostras para médias

	<i>Fim</i>	<i>Meio</i>
Média	8,90	9,55
Variância conhecida	2,72	1,61
Observações	301,00	762,00
Hipótese de diferença de média	0,00	
z	-6,19	
P(Z<=z) bi-caudal	0,00	
z crítico bi-caudal	1,96	

7.3.3 Comparação de desenhos

Tabela 7.16 - Teste de Hipóteses para a Variância DOE's Massa Volúmica

Teste F: duas amostras para variâncias

	<i>DOE1</i>	<i>DOE3</i>
Média	70,03232	69,50554
Variância	8,927004	6,732398
Observações	174	174
gl	173	173
F	1,325977	
P(F<=f) uni-caudal	0,03217	
F crítico uni-caudal	1,285054	

Tabela 7.17 - Teste de hipóteses para DOE's Humidade Relativa

Teste F: duas amostras para variâncias

	<i>DOE2</i>	<i>DOE4</i>
Média	8,642069	8,621494
Variância	1,556017	1,425171
Observações	174	174
gl	173	173
F	1,09181	
P(F<=f) uni-caudal	0,28206	
F crítico uni-caudal	1,285054	

Note-se que para a realização de todos os testes de hipóteses foi utilizada a estatística Z. Tal foi possível devido ao facto de existir sempre um grande número de dados (≥ 30). Nestes casos, é aceitável que seja feita uma aproximação da Distribuição *t-student* à Distribuição *Normal*.

7.4. Anexo IV – Cálculos DOE

Tabela 7.18 - Distâncias ao target DOE 1

DOE 1		Níveis Velocidade				
		V1	V2	V3	V4	V5
Níveis Magnetrons	P3	-5,70	-4,55	-0,66	1,62	7,51
	P2	-4,61	-3,19	0,58	4,36	8,63
	P1	-3,64	1,55	1,97	5,85	8,48

Tabela 7.19 - Distâncias ao target DOE 2

DOE 2		Níveis Velocidade				
		V1	V2	V3	V4	V5
Níveis Magnetrons	P3	-4,95	-2,53	-1,36	0,46	2,48
	P2	-3,54	-0,37	-0,44	0,77	0,58
	P1	-3,41	0,50	-0,50	-0,71	0,03

Tabela 7.20 - Distâncias ao target DOE 3

DOE 3		Níveis Velocidade				
		V1	V2	V3	V4	V5
Níveis Magnetrons	P3	-5,19	-3,47	-1,11	1,59	0,25
	P2	-4,15	-2,74	-1,30	0,17	4,08
	P1	-3,40	-0,54	-1,10	6,13	7,27

Tabela 7.21 - Distâncias ao target DOE 4

DOE 4		Níveis Velocidade				
		V1	V2	V3	V4	V5
Níveis Magnetrons	P3	3,32	6,54	6,54	7,58	9,52
	P2	3,59	5,24	8,92	10,09	10,48
	P1	5,11	8,75	7,78	8,49	9,36

7.5. Anexo V – Processo Univariadas

Tabela 7.22 - Série de dados original e respectivos resíduos

Dados		Resíduos	
Massa Volúmica	Humidade	Massa Volúmica	Humidade
68,800	8,400	-1,807	0,337
68,297	9,200	-1,607	0,992
68,645	7,940	-0,615	-0,694
73,059	9,780	3,789	1,492
70,623	9,760	-0,448	0,989
72,243	8,200	1,019	-1,012
70,642	10,110	-0,604	1,573
68,617	9,300	-2,411	0,323
68,888	8,810	-0,954	-0,285
65,558	9,030	-3,886	0,344
67,066	9,530	-1,152	0,869
65,361	9,440	-2,613	0,510
69,346	9,890	1,659	0,876
66,744	9,030	-2,066	-0,155
70,614	8,500	1,822	-0,425
71,220	9,500	1,572	1,013
73,252	6,660	2,405	-2,128
72,818	8,730	1,031	0,919
72,918	9,100	0,793	1,093
72,952	8,060	0,897	-0,612
73,400	8,000	1,307	-0,315
70,246	8,720	-2,030	0,685
72,361	8,050	1,198	-0,280
72,395	8,260	1,197	0,042
71,296	8,390	-0,442	0,246
69,350	7,800	-1,970	-0,452
69,155	7,660	-1,136	-0,370
74,038	7,200	4,309	-0,625
73,920	6,840	2,343	-0,753
72,900	6,460	0,152	-0,866
69,174	7,230	-3,149	0,155
67,953	6,830	-2,668	-0,483
67,451	6,120	-1,768	-1,209
68,333	6,030	-0,387	-0,896
70,375	8,810	1,438	2,096
67,828	7,690	-2,122	-0,197
67,428	8,370	-2,042	0,285
66,166	8,600	-2,514	0,496
65,969	8,460	-2,121	0,091

70,753	6,610	3,054	-1,755
67,671	8,310	-1,837	0,775
70,024	8,100	0,521	0,286
71,012	8,500	1,363	0,361
70,079	7,500	-0,540	-0,760
69,074	8,300	-1,428	0,372
68,907	6,910	-0,973	-1,117
71,421	6,930	1,857	-0,695
68,519	7,840	-1,980	0,546
67,805	7,310	-2,194	-0,380
69,615	6,910	0,617	-0,775
69,248	6,860	-0,276	-0,523
71,413	6,410	1,582	-0,854
69,167	7,240	-1,415	0,182
68,919	7,030	-1,329	-0,275
70,736	6,900	1,143	-0,517
69,248	6,860	-0,989	-0,450
77,146	8,980	7,036	1,719
73,969	8,900	1,161	0,737
73,998	8,620	0,456	-0,027
72,384	8,400	-0,378	-0,107
71,757	7,540	-0,385	-0,804
74,689	7,890	3,193	-0,030
72,461	7,540	-0,018	-0,321
72,525	7,200	0,182	-0,596
73,824	7,720	2,010	0,156
74,539	7,330	2,205	-0,374
76,717	8,100	3,781	0,436
67,000	8,790	-6,742	0,890
68,426	8,500	-2,386	0,115
71,894	7,880	2,978	-0,548
69,021	7,300	-1,542	-0,791
71,517	7,460	1,206	-0,230
70,741	6,760	0,176	-0,857
70,721	7,580	-0,164	0,225
68,614	6,620	-2,071	-0,917
74,926	12,300	5,065	4,976
72,303	11,190	0,515	1,658
74,693	10,290	2,352	-0,153
71,893	10,980	-0,723	1,195
75,356	10,430	3,231	0,568
71,585	8,530	-1,186	-1,264
72,591	7,630	0,421	-1,212
70,353	7,800	-1,268	-0,191
72,164	6,360	1,162	-1,484

71,811	9,000	0,663	1,734
76,079	5,670	4,617	-2,379
72,601	5,660	-0,431	-1,603
74,660	5,520	1,915	-0,925
73,928	7,840	1,251	1,458
69,612	6,370	-3,295	-0,975
70,552	7,670	-0,496	0,390
72,518	5,900	2,181	-1,580
71,726	6,000	0,391	-1,037
70,935	6,370	-0,583	-0,277
71,325	5,720	0,312	-1,111
69,979	6,830	-0,989	0,189
69,406	9,040	-1,135	2,080
67,914	8,520	-2,070	0,338
66,968	8,590	-2,294	0,092
68,903	9,700	0,380	1,299




Figura 7.2 - FAC Iteração 1 (Massa Volúmica)




Figura 7.3 - FACP Iteração 1 (Massa Volúmica)




Figura 7.4 - FAC Iteração 1 (Humidade Relativa)




Figura 7.5 - FACP Iteração 1 (Humidade Relativa)

```

Variable: Massa Vo
Transformations:
Model: (2,0,0)
No. of obs.:100 Initial SS=5016E2 Final SS=448,07 (,0893%) MS=4,6192
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
      Const.  p(1)  p(2)
Estimate: 70,606 ,38841 ,24913
Std.Err.: ,58106 ,09905 ,10064

```

Figura 7.6 – Modelo ARIMA Iteração 1 (Massa Volúmica)

```

Variable: HUMIDADE
Transformations:
Model: (2,0,0)
No. of obs.:100 Initial SS=6534,1 Final SS=106,90 (1,636%) MS=1,1020
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
      Const.  p(1)  p(2)
Estimate: 8,0626 ,43002 ,24445
Std.Err.: ,31176 ,09989 ,10035

```

Figura 7.7 - Modelo ARIMA Iteração 1 (Humidade Relativa)




Figura 7.8 - Carta de Controlo X Iteração 1 (Massa Volúmica)




Figura 7.9 - Carta de Controlo MR Iteração 1 (Massa Volúmica)




Figura 7.10 - Carta de Controle X Iteração 1 (Humidade Relativa)




Figura 7.11 - Carta de Controle MR Iteração 1 (Humidade Relativa)

Substituíram-se nesta etapa as causas especiais de variação pelos respectivos valores esperados, em conformidade com o que foi referido ao longo da dissertação. O processo iterativo foi executado de forma análoga até à obtenção de um modelo sem causas especiais de variação para a Fase 1.

```

Variable: Massa Vo
Transformations:
      Model: (2,0,0)
No. of obs.:100  Initial SS=5015E2  Final SS=382,62 (,0763%)  MS=3,9445
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
      Const.  p(1)  p(2)
Estimate: 70,553 ,42951 ,25456
Std.Err.: ,61340 ,09898 ,10083

```

Figura 7.12 - Modelo ARIMA Iteração 2 (Massa Volúmica)

```

Variable: Humidade
Transformations:
      Model: (2,0,0)
No. of obs.:100  Initial SS=6408,2  Final SS=87,292 (1,362%)  MS=,89992
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
      Const.  p(1)  p(2)
Estimate: 8,0111 ,49740 ,20519
Std.Err.: ,30775 ,10102 ,10168

```

Figura 7.13 - Modelo ARIMA Iteração 2 (Humidade Relativa)




Figura 7.14 - Carta de Controle X Iteração 2 (Massa Volúmica)




Figura 7.15 - Carta de Controle MR Iteração 2 (Massa Volúmica)




Figura 7.16 - Carta de Controle X Iteração 2 (Humidade Relativa)




Figura 7.17 - Carta de Controle MR Iteração 2 (Humidade Relativa)

```

Variable: Massa Vo
Transformations:
Model: (1,0,0)
No. of obs.:100 Initial SS=5008E2 Final SS=382,48 (,0764%) MS=3,9029
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1)
Estimate: 70,635 ,59091
Std.Err.: ,47547 ,08253

```

Figura 7.18 - Modelo ARIMA Iteração 3 (Massa Volúmica)

```

Variable: Humidade
Transformations:
Model: (1,0,0)
No. of obs.:100 Initial SS=6337,5 Final SS=84,998 (1,341%) MS=,86733
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1)
Estimate: 7,9244 ,61952
Std.Err.: ,23994 ,08152

```

Figura 7.19 - Modelo ARIMA Iteração 3 (Humidade Relativa)




Figura 7.20 - Carta de Controlo X Iteração 3 (Massa Volúmica)




Figura 7.21 - Carta de Controle MR Iteração 3 (Massa Volúmica)




Figura 7.22 - Carta de Controle X Iteração 3 (Humidade Relativa)




Figura 7.23 - Carta de Controle MR Iteração 3 (Humidade Relativa)

```

Variable: Humidade
Transformations:
Model: (1,0,0)
No. of obs.:100 Initial SS=6372,6 Final SS=77,172 (1,211%) MS=,78747
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
      Const.  p(1)
Estimate: 7,9581 ,66392
Std.Err.: ,25680 ,07784

```

Figura 7.24 - Modelo ARIMA Iteração 4 (Humidade Relativa)




Figura 7.25 - Carta de Controlo X Iteração 4 (Humidade Relativa)




Figura 7.26 - Carta de Controlo MR Iteração 4 (Humidade Relativa)




Figura 7.27 - FACE Iteração Final (Massa Volúmica)




Figura 7.28 - FACPE Iteração Final (Massa Volúmica)




Figura 7.29 - FACE Iteração Final (Humidade Relativa)




Figura 7.30 - FACPE Iteração Final (Humidade Relativa)




Figura 7.31 - Histograma Resíduos, Teste Kolmogorov-Smirnov (Massa Volúmica)




Figura 7.32 - Histograma Resíduos, Teste Kolmogorov-Smirnov (Humidade Relativa)




Figura 7.33 - Carta de controlo dos Erros de Previsão, Fase 2 (Massa Volúmica)




Figura 7.34 - Carta de controlo das Amplitudes Móveis, Fase 2 (Massa Volúmica)




Figura 7.35 - Carta de controlo dos Erros de Previsão, Fase 2 (Humidade Relativa)




Figura 7.36 - Carta de controlo das Amplitudes Móveis, Fase 2 (Humidade Relativa)

7.6. Anexo VI – Processo Multivariadas

Similarmente ao que se sucedeu no

Anexo V – Processo Univariadas, o processo para definição do modelo na Fase 1 das cartas Multivariadas é iterativo. Uma vez mais serão apresentadas a várias iterações dos modelos matemáticos, sendo apresentados os pontos que foram retirados em cada fase. Note-se, uma vez mais que neste caso os pontos foram tratados tendo como base no método aplicado à estatística d. A título de exemplo é também apresentada em seguida a Tabela 7.23 associado às decisões tomadas para a primeira iteração. Caso nenhuma das estatísticas seja sinalizada pelo método da estatística d, significa que a causa especial se deve à correlação entre variáveis, como é o caso do ponto 86 na primeira iteração.




Figura 7.37- FAC Iteração 1 (Massa Volúmica)




Figura 7.38 - FACP Iteração 1 (Massa Volúmica)




Figura 7.39 - FAC Iteração 1 (Humidade)




Figura 7.40 - FACP Iteração 1 (Humidade)

Tabela 7.23 - Causas Especiais de Variação Carta T^2 , Fase 1, Iteração 1

N.º	T2	LSC	Decisão
1	1,00	10,00577	0
2	1,88	10,00577	0
3	0,93	10,00577	0
4	8,84	10,00577	0
5	1,42	10,00577	0
6	1,60	10,00577	0
7	3,58	10,00577	0
8	1,71	10,00577	0
9	0,45	10,00577	0
10	4,36	10,00577	0
11	1,29	10,00577	0
12	2,12	10,00577	0
13	2,29	10,00577	0
14	1,37	10,00577	0
15	1,08	10,00577	0
16	2,62	10,00577	0
17	7,31	10,00577	0
18	1,79	10,00577	0
19	2,16	10,00577	0
20	0,67	10,00577	0

21	0,56	10,00577	0				
22	1,61	10,00577	0				
23	0,47	10,00577	0				
24	0,44	10,00577	0				
25	0,12	10,00577	0				
26	1,65	10,00577	0				
27	0,68	10,00577	0				
28	5,49	10,00577	0				
29	2,08	10,00577	0				
30	1,09	10,00577	0				
31	2,87	10,00577	0				
32	2,75	10,00577	0				
33	3,58	10,00577	0				
34	1,32	10,00577	0				
35	7,83	10,00577	0				
36	1,49	10,00577	0				
37	1,23	10,00577	0				
38	1,96	10,00577	0				
39	1,30	10,00577	0				
40	6,16	10,00577	0				
41	1,58	10,00577	0				
42	0,24	10,00577	0				
43	0,86	10,00577	0				
44	1,04	10,00577	0				
45	0,69	10,00577	0				
46	2,38	10,00577	0				
47	1,45	10,00577	0				
48	1,37	10,00577	0				
49	1,83	10,00577	0				
50	0,90	10,00577	0				
51	0,46	10,00577	0				
52	1,53	10,00577	0				
53	0,59	10,00577	0				
54	0,72	10,00577	0				
55	0,65	10,00577	0	$T^2(j)$		$dj = T^2 - T^2(j)$	
56	0,69	10,00577	0	(MV)	Humidade	MV - T^2	Humidade - T^2
57	21,79	10,00577	1	4,275	14,274	17,52	7,52
58	1,40	10,00577	0				
59	0,06	10,00577	0				
60	0,07	10,00577	0				
61	1,08	10,00577	0				
62	3,01	10,00577	0				
63	0,15	10,00577	0				
64	0,51	10,00577	0				

65	1,31	10,00577	0				
66	1,47	10,00577	0	$T^2(j)$		$dj = T^2 - T^2(j)$	
67	4,89	10,00577	0	(MV)	Humidade	MV - T^2	Humidade - T^2
68	13,33	10,00577	1	1,1474	13,1052	12,18	0,22
69	1,65	10,00577	0				
70	2,72	10,00577	0				
71	1,91	10,00577	0				
72	0,45	10,00577	0				
73	1,07	10,00577	0				
74	0,08	10,00577	0	$T^2(j)$		$dj = T^2 - T^2(j)$	
75	2,95	10,00577	0	(MV)	Humidade	MV - T^2	Humidade - T^2
76	50,12	10,00577	1	35,829	7,398	14,29	42,72
77	4,36	10,00577	0				
78	1,60	10,00577	0				
79	2,09	10,00577	0				
80	3,99	10,00577	0				
81	3,13	10,00577	0				
82	2,13	10,00577	0				
83	0,59	10,00577	0				
84	3,29	10,00577	0	$T^2(j)$		$dj = T^2 - T^2(j)$	
85	4,86	10,00577	0	(MV)	Humidade	MV - T^2	Humidade - T^2
86	12,30	10,00577	1	8,194	6,147	4,11	6,15
87	4,04	10,00577	0				
88	1,97	10,00577	0				
89	4,04	10,00577	0				
90	5,36	10,00577	0				
91	0,26	10,00577	0				
92	4,36	10,00577	0				
93	1,56	10,00577	0				
94	0,25	10,00577	0				
95	1,79	10,00577	0				
96	0,30	10,00577	0				
97	6,30	10,00577	0				
98	1,29	10,00577	0				
99	1,53	10,00577	0				
100	2,67	10,00577	0				

Substituindo os pontos pelos seus valores esperados e repetindo a análoga, tiveram lugar os seguintes passos:

```
Variable: Massa Vo
Transformations:
Model: (2,0,0)
No. of obs.:100 Initial SS=5016E2 Final SS=448,07 (,0893%) MS=4,6192
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1) p(2)
Estimate: 70,606 ,38841 ,24913
Std.Err.: ,58106 ,09905 ,10064
```

Figura 7.41 - Modelo ARIMA Iteração 1 (Massa Volúmica) T^2

```
Variable: HUMIDADE
Transformations:
Model: (2,0,0)
No. of obs.:100 Initial SS=6534,1 Final SS=106,90 (1,636%) MS=1,1020
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1) p(2)
Estimate: 8,0626 ,43002 ,24445
Std.Err.: ,31176 ,09989 ,10035
```

Figura 7.42 -Modelo ARIMA Iteração 1 (Humidade Relativa) T^2

Substituição das seguintes causas especiais de variação:

Iteração 2:

- Massa Volúmica: nenhum
- Humidade: 76
- Ambos (devido à correlação entre variáveis: nenhum).

```
Variable: Massa Vo
Transformations:
Model: (1,0,0)
No. of obs.:100 Initial SS=5001E2 Final SS=360,33 (,0720%) MS=3,6769
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1)
Estimate: 70,589 ,59629
Std.Err.: ,46739 ,08214
```

Figura 7.43 - Modelo ARIMA Iteração 2 (Massa Volúmica) T^2

```

Variable: Humidade
Transformations:
Model: (1,0,0)
No. of obs.:100 Initial SS=6441,2 Final SS=95,303 (1,480%) MS=,97248
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1)
Estimate: 7,9745 ,57730
Std.Err.: ,22979 ,08442

```

Figura 7.44 - Modelo ARIMA Iteração 2 (Humidade Relativa) T²

Iteração 3:

- Massa Volúmica: Nenhum
- Humidade : 78
- Correlação entre variáveis: Nenhum

```

Variable: Massa Vo
Transformations:
Model: (1,0,0)
No. of obs.:100 Initial SS=5001E2 Final SS=360,33 (,0720%) MS=3,6769
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1)
Estimate: 70,589 ,59629
Std.Err.: ,46739 ,08214

```

Figura 7.45 - Modelo ARIMA Iteração 3 (Massa Volúmica) T²

```

Variable: Humidade
Transformations:
Model: (1,0,0)
No. of obs.:100 Initial SS=6373,7 Final SS=88,588 (1,390%) MS=,90396
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1)
Estimate: 7,9398 ,57525
Std.Err.: ,22061 ,08476

```

Figura 7.46 - Modelo ARIMA Iteração 3 (Humidade Relativa) T²

Iteração 4:

- Massa Volúmica: nenhum
- Humidade: 79
- Correlação entre variáveis: Nenhum

```

Variable: Massa Vo
Transformations:
Model: (1,0,0)
No. of obs.:100 Initial SS=5001E2 Final SS=360,33 (,0720%) MS=3,6769
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1)
Estimate: 70,589 ,59629
Std.Err.: ,46739 ,08214

```

Figura 7.47 - Modelo ARIMA Iteração 4 (Massa Volúmica) T²

```

Variable: Humidade
Transformations:
Model: (1,0,0)
No. of obs.:100 Initial SS=6327,8 Final SS=89,063 (1,408%) MS=,90881
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1)
Estimate: 7,9099 ,54367
Std.Err.: ,20658 ,08699

```

Figura 7.48 - Modelo ARIMA Iteração 4 (Humidade) T²

Iteração 5:

- Massa Volúmica: 80
- Humidade: 80
- Correlação entre variáveis: Nenhum

```

Variable: Massa Vo
Transformations:
Model: (1,0,0)
No. of obs.:100 Initial SS=5001E2 Final SS=360,33 (,0720%) MS=3,6769
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1)
Estimate: 70,589 ,59629
Std.Err.: ,46739 ,08214

```

Figura 7.49 - Modelo ARIMA Iteração 5 (Massa Volúmica) T²

```

Variable: Humidade
Transformations:
Model: (2,0,0)
No. of obs.:100 Initial SS=6268,4 Final SS=81,329 (1,297%) MS=,83844
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1) p(2)
Estimate: 7,9152 ,41653 ,20841
Std.Err.: ,24006 ,10125 ,10197

```

Figura 7.50 - Modelo ARIMA Iteração 5 (Humidade Relativa) T²

Iteração 6: Foi atingido o controlo do processo

```

Variable: Humidade
Transformations:
Model: (2,0,0)
No. of obs.:100 Initial SS=6221,0 Final SS=73,944 (1,189%) MS=,76231
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1) p(2)
Estimate: 7,9049 ,41542 ,23719
Std.Err.: ,24690 ,10075 ,10168

```

Figura 7.51 - Modelo ARIMA Iteração 6 (Massa Volúmica) T²

```

Variable: Massa Vo
Transformations:
Model: (1,0,0)
No. of obs.:100 Initial SS=4995E2 Final SS=341,24 (,0683%) MS=3,4820
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
Const. p(1)
Estimate: 70,547 ,60439
Std.Err.: ,46371 ,08155

```

Figura 7.52 - Modelo ARIMA Iteração 6 (Humidade Relativa) T²




Figura 7.53 - FACE Final T² (Massa Volúmica)




Figura 7.54 - FACPE Final T² (Massa Volúmica)




Figura 7.55 - FACE Final T² (Humidade Relativa)




Figura 7.56 - FACPE Final T² (Humidade Relativa)

Tabela 7.24 - Matriz de covariâncias S, Fase 1, T²

Matriz covariâncias S		
S11	S22	S12
3,4937	0,6954	-0,35032376

$\bar{X} =$

0,0267
-0,0167

Figura 7.57 - Vector Média Final, Fase 1, T²

Índices de capacidade Multivariados		
CpM	PV	LI
1,98	0,97	1,00

Figura 7.58 - Índices de capacidade do processo, Fase 1, T₂




Figura 7.59 - Histograma Resíduos, Teste Kolmogorov-Smirnov (Massa Volúmica) T²




Figura 7.60 - Histograma Resíduos, Teste Kolmogorov-Smirnov (Humidade Relativa) T^2




Figura 7.61 - Carta de Controlo T^2 , Fase 2